

Penerapan AI

Pada Infrastruktur, Rekayasa Teknik Sipil dan Konstruksi

Dr. Agus Wibowo, M.Kom, M.Si, MM.



YAYASAN PRIMA AGUS TEKNIK



Dr. Agus Wibowo, M.Kom, M.Si, MM.

Penerapan AI Pada Infrastruktur, Rekayasa Teknik Sipil dan Konstruksi



YAYASAN PRIMA AGUS TEKNIK

PENERBIT :
YAYASAN PRIMA AGUS TEKNIK
Jl. Majapahit No. 605 Semarang
Telp. (024) 6723456. Fax. 024-6710144
Email : penerbit_ypat@stekom.ac.id

ISBN 978-634-7227-39-3 (PDF)



9

786347

227393

Penerapan AI pada Infrastruktur, Rekayasa Teknik Sipil dan Konstruksi

Penulis :

Dr. Agus Wibowo, M.Kom, M.Si, MM.

ISBN : 978-634-7227-39-3

Editor :

Dr. Joseph Teguh Santoso, S.Kom., M.Kom.

Penyunting :

Dr. Mars Caroline Wibowo. S.T., M.Mm.Tech

Desain Sampul dan Tata Letak :

Irdha Yuniato, S.Ds., M.Kom

Penebit :

Yayasan Prima Agus Teknik Bekerja sama dengan
Universitas Sains & Teknologi Komputer (Universitas STEKOM)

Anggota IKAPI No: 279 / ALB / JTE / 2023

Redaksi :

Jl. Majapahit no 605 Semarang

Telp. 08122925000

Fax. 024-6710144

Email : penerbit_ypat@stekom.ac.id

Distributor Tunggal :

Universitas STEKOM

Jl. Majapahit no 605 Semarang

Telp. 08122925000

Fax. 024-6710144

Email : info@stekom.ac.id

Hak cipta dilindungi undang-undang

Dilarang memperbanyak karya tulis ini dalam bentuk dan dengan cara
apapun tanpa ijin dari penulis

KATA PENGANTAR

Puji syukur penulis panjatkan kepada Tuhan Yang Maha Esa atas rahmat dan karunia-Nya sehingga karya dengan topik ***“Penerapan Kecerdasan Buatan pada Infrastruktur, Rekayasa Teknik Sipil, dan Konstruksi”*** ini dapat terselesaikan dengan baik. Perkembangan teknologi kecerdasan buatan (Artificial Intelligence/AI) telah membawa perubahan besar dalam berbagai bidang, termasuk sektor infrastruktur, teknik sipil, dan konstruksi. Penerapan AI tidak hanya meningkatkan efisiensi perencanaan dan pelaksanaan proyek, tetapi juga memberikan solusi inovatif dalam analisis data, pemodelan prediktif, deteksi kerusakan, serta manajemen risiko. Dengan demikian, AI berpotensi besar dalam mendukung terciptanya pembangunan yang lebih cerdas, berkelanjutan, dan aman.

Bab 1 Membahas dasar-dasar kecerdasan buatan dan konsep jaringan saraf tiruan (JST), khususnya model CNN yang diaplikasikan pada infrastruktur sipil. Bab ini menjelaskan arsitektur CNN, model perseptron multi-lapisan, serta implementasi CNN 1D dalam menganalisis data infrastruktur untuk mendukung keputusan teknik. BAB 2 Mengulas penggunaan AI, khususnya JST dan regresi linier, untuk memprediksi perilaku keselamatan pada struktur sipil. Disajikan metodologi pengumpulan data, pemodelan, serta analisis dan interpretasi hasil prediksi untuk meningkatkan keselamatan konstruksi. Bab 3 Membahas penerapan pembelajaran mesin berbasis data eksperimen untuk memprediksi respons balok Fiber Reinforced Polymer (FRP). Bab ini mengupas perbandingan berbagai model dan teknik pembelajaran mesin yang efektif untuk prediksi struktur tersebut.

Pada bab 4 Memperkenalkan metode kecerdasan buatan berbasis algoritma genetika dan pemrograman ekspresi genetik (GEP) dalam memodelkan sifat beton berkinerja tinggi (High Performance Concrete - HPC), khususnya untuk memprediksi kuat tekan beton.

Selanjutnya Bab 5 Menyajikan pendekatan pengumpulan data gelombang akustik-emisi (AE) dari struktur untuk analisis kerusakan dan pemodelan data kompleks. Bab ini mengupas teknik analisis data dan penerapan metode berbasis data untuk evaluasi struktur. Bab 6 akan Membahas teknik pemrosesan citra dan CNN dalam mendeteksi retak pada beton struktural. Termasuk proses pengujian material dan metode deteksi kerusakan yang diotomatisasi untuk mempermudah diagnosis kondisi beton.

Bab 7 Menjelaskan kategori-kategori kecerdasan buatan dan membahas penelitian terkini atau state-of-the-art di bidang infrastruktur sipil yang memanfaatkan AI, termasuk tren dan aplikasi praktis. Bab 8 Mengulas survei literatur dan studi scientometrik terkait penggunaan AI dalam penelitian material beton. Analisis ko-occurrence kata kunci, pola sitasi, serta pembahasan tren riset dan arah masa depan di bidang ini. Pada Bab 9 Menerangkan konsep analisis keandalan dan penerapan metode statistik Kriging serta simulasi Monte Carlo dengan pembelajaran aktif (AK-MCS) untuk evaluasi keamanan struktur dan pengambilan keputusan berbasis data.

Selanjutnya Bab 10 Mendalami teknik estimasi Bayesian dan penggunaannya dalam klasifikasi bertingkat kerusakan pada struktur jembatan menggunakan Finite Element Method (FEM) dan validasi model untuk pengawasan kondisi struktural. Bab 11 Membahas integrasi

pembelajaran mesin dengan data dari sensor IoT untuk analisis kinerja beton secara real-time, mendukung pemantauan dan perawatan struktur dengan pendekatan berbasis data.

Pada Bab 12 Menguraikan penerapan jaringan saraf tiruan dalam pembelajaran mendalam untuk memodelkan dan menganalisis sistem struktural nonlinier serta verifikasi kinerja model AI dalam prediksi respons struktural. Bab 13 Menyajikan sinergi antara model Finite Element (FE) dan AI untuk deteksi kerusakan beton, serta pembuatan basis data dan implementasi AI dalam konteks pengujian dan pemodelan kerusakan struktural. Bab 14 Mengulas penerapan pembelajaran mendalam pada sistem transportasi siber-fisik (TCPS), termasuk pengembangan model, kerangka kerja hardware-software, dan aplikasi AI untuk optimalisasi pengelolaan sistem transportasi. Bab 15 Mengupas aplikasi AI dalam industri konstruksi, mulai dari keselamatan kerja, teknik pengumpulan data, hingga otomasi dan pertimbangan implementasi teknologi AI untuk meningkatkan produktivitas dan keamanan.

Pada Bab 16 akan Membahas penggunaan pembelajaran mesin untuk memodelkan dan memprediksi kejadian kebakaran pada struktur bangunan, termasuk pengembangan model simulasi dan studi kasus penerapan di lapangan. Bab 17 Memaparkan pengembangan model AI untuk memprediksi sifat mekanik beton UHPC yang dipengaruhi oleh suhu, tantangan riset terkini, serta arah pengembangan teknologi dalam material beton berperforma tinggi.

Bab 18 sekaligus menjadi penutup buku ini akan Mengkaji manajemen keamanan dan deteksi kebakaran terowongan dengan pendekatan AI dan sensor IoT, termasuk prediksi kejadian dan implementasi sistem manajemen kebakaran yang cerdas dan terintegrasi.

Buku ini diharapkan dapat memberikan wawasan mengenai bagaimana AI dapat diintegrasikan ke dalam praktik rekayasa dan konstruksi modern, serta membuka ruang diskusi lebih lanjut mengenai tantangan dan peluang di masa depan. Semoga buku ini bermanfaat bagi para akademisi, praktisi, maupun mahasiswa yang tertarik dalam mengkaji peran teknologi cerdas pada bidang infrastruktur dan konstruksi.

Akhir kata, penulis menyampaikan terima kasih kepada semua pihak yang telah memberikan dukungan, baik secara langsung maupun tidak langsung, dalam penyusunan karya ini.

Semarang, 04 September 2025

Penulis

Dr. Agus Wibowo, M.Kom, M.Si, MM.

Mengintegrasikan kecerdasan buatan dalam rekayasa teknik sipil sebagai fondasi kemajuan infrastruktur masa depan yang berkelanjutan dan inovatif. Buku ini dipersembahkan dengan hormat kepada para akademisi, praktisi, dan seluruh civitas akademika yang berkomitmen mengembangkan ilmu pengetahuan dan teknologi dalam bidang infrastruktur, rekayasa teknik sipil, dan konstruksi. Semoga karya ini dapat menjadi sumber referensi yang bermanfaat dalam mengaplikasikan kecerdasan buatan untuk meningkatkan efisiensi, keamanan, dan mutu pembangunan nasional. Pemanfaatan kecerdasan buatan sebagai pilar inovasi dalam pengembangan infrastruktur dan rekayasa teknik sipil yang berkelanjutan dan berstandar global.

Dr. Agus Wibowo, M.Kom, M.Si, MM.

DAFTAR ISI

KATA PENGANTAR.....	ii
DAFTAR ISI.....	v
BAB 1 JARINGAN SARAF TIRUAN KONVOLUSIONAL PADA INFRASTRUKTUR SIPIL....	1
1.1 Latar Belakang Kecerdasan Buatan	1
1.2 Jaringan Syaraf Tiruan (JST)	3
1.3 Perseptron Multi-Lapisan	7
1.4 Jaringan Saraf Tiruan Konvolusional (CNN)	14
1.5 Penggunaan CNN 1D Dalam Aplikasi Infrastruktur Sipil.....	24
1.6 Kesimpulan	26
BAB 2 PREDIKSI PERILAKU KESELAMATAN DENGAN AI DAN REGRESI LINIER	27
2.1 Pendahuluan.....	27
2.2 Kumpulan Data	28
2.3 Model Jaringan Saraf Tiruan Dan Regresi Linier.....	30
2.4 Prediksi Keselamatan.....	37
2.5 Kesimpulan	39
BAB 3 PEMBELAJARAN MESIN UNTUK PREDIKSI BALOK FRP	41
3.1 Pendahuluan.....	41
3.2 Basis Data Eksperimental	43
3.3 Pembelajaran Mesin Berbasis Data Untuk Prediksi Respons	44
3.4 Perbandingan Permodelan	55
3.5 Kesimpulan	57
BAB 4 PEMROGRAMAN EKSPRESI GENETIK BETON	58
4.1 Pendahuluan.....	58
4.2 Model Berbasis Kecerdasan Buatan Untuk Sifat HPC.....	60
4.3 Algoritma Genetika Dan Perluasannya.....	61
4.4 Algoritma Pemrograman Ekspresi Gen (GEP).....	62
4.5 Model GEP Untuk Kuat Tekan HPC	67
BAB 5 BASIS DATA PENILAIAN STRUKTUR DAN ANALISIS KOMPLEKS.....	72
5.1 Pendahuluan.....	72
5.2 Sumber Gelombang Ae Pada Berbagai Struktur	72
5.3 Pendekatan Analisis Data	76
5.4 Penggunaan Metode Berbasis Data Dalam Data AE	90
5.5 Kesimpulan	97
BAB 6 DETEKSI OTOMATIS RETAK BETON STRUKTURAL	98
6.1 Pendahuluan.....	98
6.2 Teknik Pemrosesan Citra.....	100
6.3 Material	103
6.4 Pengujian Spesimen Pada Suhu Tinggi	103
6.5 Metodologi Untuk Deteksi Retak	107

6.6	Deteksi Kerusakan Dari Metode CNN.....	110
6.7	Kesimpulan	113
BAB 7	KECERDASAN BUATAN DALAM INFRASTRUKTUR SIPIL	114
7.1	Pendahuluan.....	114
7.2	Kategori Kecerdasan Buatan.....	114
7.3	Penelitian Terkini (State-Of-The-Art) Dalam Bidang Kecerdasan Buatan.....	116
7.4	Kesimpulan	127
BAB 8	KECERDASAN BUATAN DALAM MATERIAL BETON SCIENTOMETRIK.....	129
8.1	Pendahuluan.....	129
8.2	Survei Literatur	130
8.3	Analisis Ko-Okurensi Kata Kunci Sebagai Minat Penelitian Utama.....	132
8.4	Pola Sitasi: Analisis Ko-Sitasi Dokumen	138
8.5	Pembahasan Dan Tren Masa Depan.....	142
8.6	Kesimpulan	145
BAB 9	KEANDALAN KRIGING UNTUK PENILAIAN KEAMANAN STRUKTURAL.....	146
9.1	Pendahuluan.....	146
9.2	Konsep Kunci Analisis Keandalan	147
9.3	Kriging.....	151
9.4	Simulasi Monte Carlo Kriging Pembelajaran Aktif (AK-MCS)	165
9.5	Penerapan AK-MCS.....	177
BAB 10	TEKNIK ESTIMASI BAYESIAN UNTUK KLASIFIKASI KERUSAKAN BERTINGKAT..	193
10.1	Pendahuluan.....	193
10.2	Fem Kendaraan-Jembatan Yang Disederhanakan	193
10.3	Sistem Jembatan-Kendaraan Subjek	206
10.4	Validasi Model Dan Pemetaan Kerusakan	207
10.5	Demonstrasi Teknik Estimasi Bayesian Untuk DBHM.....	209
10.6	Kesimpulan	218
BAB 11	PEMBELAJARAN MESIN DAN DATA IOT DALAM ANALISIS KINERJA BETON	220
11.1	Pendahuluan.....	220
11.2	Algoritma Pembelajaran Mesin	221
11.3	Kesimpulan	233
BAB 12	PEMBELAJARAN MENDALAM STRUKTUR NONLINIER	234
12.1	Pendahuluan.....	234
12.2	Jaringan Saraf Tiruan Dalam	235
12.3	Verifikasi Kinerja	240
12.4	Penerapan Kedl Pada Sistem Nonlinier	247
12.5	Kesimpulan	252
BAB 13	DETEKSI KERUSAKAN BETON DENGAN FINITE ELEMENT DAN AI	253
13.1	Pendahuluan.....	253
13.2	Jaringan Syaraf Tiruan	256
13.3	Metodologi Sinergi AI-FE	262

13.4	Pembuatan Basis Data Dan Implementasi AI	268
13.5	Pemodelan AI Pada Basis Data	274
13.6	Kesimpulan	286
BAB 14	PEMBELAJARAN MENDALAM DALAM SISTEM SIBER-FISIK TRANSPORTASI ...	287
14.1	Pendahuluan.....	287
14.2	Kecerdasan Buatan, Pembelajaran Mesin, Dan Pembelajaran Mendalam	288
14.3	Sejarah Singkat Pembelajaran Mendalam.....	289
14.4	Model Pembelajaran Mendalam Untuk Aplikasi Tcps.....	289
14.5	Pengembangan Model Pembelajaran Mendalam Untuk Aplikasi TCPS.....	295
14.6	Kerangka Kerja Hardware–Software Untuk Pembelajaran Mendalam	297
14.7	Aplikasi Pembelajaran Mendalam Dalam TCPS.....	299
14.8	Kesimpulan	302
BAB 15	KECERDASAN BUATAN DALAM INDUSTRI KONSTRUKSI	303
15.1	Pendahuluan.....	303
15.2	Keselamatan Konstruksi	304
15.3	Teknik Pengumpulan Data	306
15.4	Aplikasi AI Dalam Konstruksi	313
15.5	Pertimbangan Penerapan Ai Dan Otomasi Dalam Konstruksi.....	322
15.6	Kesimpulan	326
BAB 16	PEMBELAJARAN MESIN UNTUK REKAYASA KEBAKARAN STRUKTURAL.....	329
16.1	Pendahuluan.....	329
16.2	Pembelajaran Mesin Dalam SFE	330
16.3	Kerangka Kerja Pengembangan Model Pengganti.....	331
16.4	Contoh Studi Kasus	333
16.5	Keterbatasan Pendekatan Pembelajaran Mesin	347
16.6	Kesimpulan	350
BAB 17	AI UNTUK PREDIKSI SIFAT MEKANIK BETON ULTRA-HIGH PERFORMANCE.....	351
17.1	Pendahuluan.....	351
17.2	Sifat Mekanik UHPC Yang Bergantung Pada Suhu	353
17.3	Pengembangan Model Kecerdasan Buatan.....	357
17.4	Derivasi Model Properti Mekanik.....	358
17.5	Tantangan Saat Ini Dan Penelitian Mendatang	361
17.6	Kesimpulan	362
BAB 18	MANAJEMEN TEROWONGAN CERDAS BERBASIS AI DAN SENSOR.....	363
18.1	Pendahuluan.....	363
18.2	Dinamika Dan Data Kebakaran Terowongan	366
18.3	Prediksi Kebakaran Terowongan Oleh IoT Dan AI	373
18.4	Sistem Manajemen Keselamatan Kebakaran Terowongan Cerdas	378
18.5	Kesimpulan Dan Perspektif.....	382
DAFTAR PUSTAKA	383

BAB 1

JARINGAN SARAF TIRUAN KONVOLUSIONAL PADA INFRASTRUKTUR SIPIL

1.1 LATAR BELAKANG KECERDASAN BUATAN

Kecerdasan Buatan (AI) adalah kemampuan yang ditunjukkan oleh mesin atau komputer untuk meniru kecerdasan manusia dalam menyelesaikan tugas-tugas dan memecahkan masalah yang kompleks. AI berkembang sebagai bidang interdisipliner dengan subset utama berupa Pembelajaran Mesin (*Machine Learning/ML*) dan Pembelajaran Mendalam (*Deep Learning/DL*), yang kini semakin banyak diimplementasikan dalam berbagai disiplin ilmu dan rekayasa.

Algoritma AI dapat diprogram untuk menjalankan tugas-tugas tertentu, sehingga pendekatan berbasis pengetahuan ini dapat diterapkan dalam berbagai aplikasi. Meskipun sistem AI berbasis pengetahuan kadang masih mengalami kesulitan dalam tugas-tugas manusia yang terkesan sederhana seperti pengenalan objek, wajah, atau suara para peneliti terus mengembangkan cara untuk memberikan pengetahuan yang intuitif dan masuk akal kepada komputer.

Pembelajaran Mesin (*Machine Learning*) diperkenalkan sebagai bagian dari AI untuk mengatasi kelemahan pendekatan berbasis pengetahuan. ML didefinisikan sebagai kemampuan sistem untuk belajar secara otomatis dari data, meningkatkan kinerja berdasarkan pengalaman, dan beradaptasi tanpa instruksi eksplisit. Algoritma dan model statistik menjadi komponen utama dalam ML untuk menarik kesimpulan berdasarkan pola data. Pada algoritma ML sederhana, data perlu disajikan berdasarkan sejumlah fitur tertentu melalui proses yang disebut ekstraksi fitur.

Tahap selanjutnya adalah pelatihan sistem, di mana data yang telah diproses digunakan oleh algoritma ML untuk mempelajari korelasi antarfitur atau dengan data lainnya. Algoritma ML dapat diklasifikasikan menjadi dua kategori utama: pembelajaran terawasi (*supervised learning*) dan pembelajaran tanpa pengawasan (*unsupervised learning*). Algoritma supervised learning bekerja dengan format masukan-keluaran, dengan tujuan memetakan masukan terhadap keluaran yang ditargetkan. Algoritma ini memerlukan "pengawas" yang memberikan label akurat untuk setiap titik data sebelum pelatihan. Sementara itu, algoritma unsupervised learning hanya menggunakan data masukan tanpa pengawasan penargetan, dan bertujuan untuk memahami distribusi data guna memperoleh informasi yang bermakna.

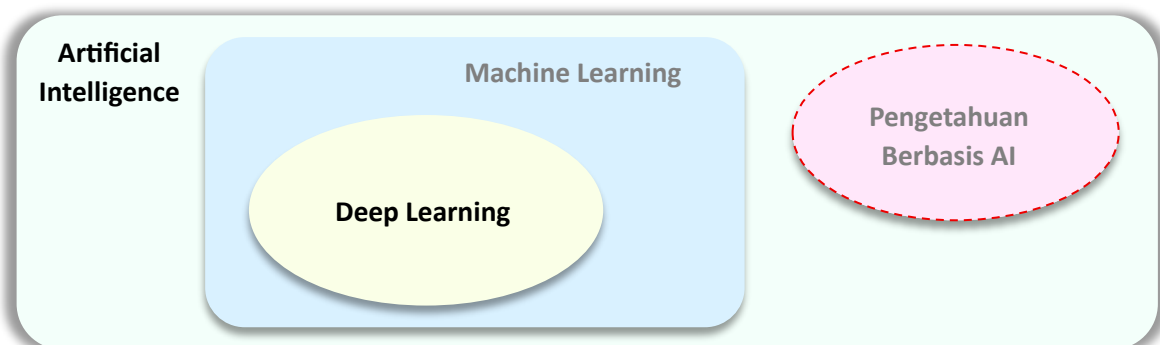
Aplikasi ML digunakan secara luas di berbagai bidang teknik. Proses dalam ML dapat dikategorikan menjadi klasifikasi, regresi, prediksi, dan pengelompokan. Klasifikasi bertujuan menetapkan kategori untuk masukan, regresi menentukan hubungan antara masukan dan keluaran, prediksi merupakan jenis regresi khusus untuk memperkirakan nilai masa depan dalam deret waktu, sedangkan pengelompokan membagi data menjadi beberapa kelompok berdasarkan kemiripan biasanya dengan teknik unsupervised learning seperti Self-Organizing

Maps. Di sisi lain, metode supervised learning umumnya digunakan untuk klasifikasi, regresi, dan prediksi.

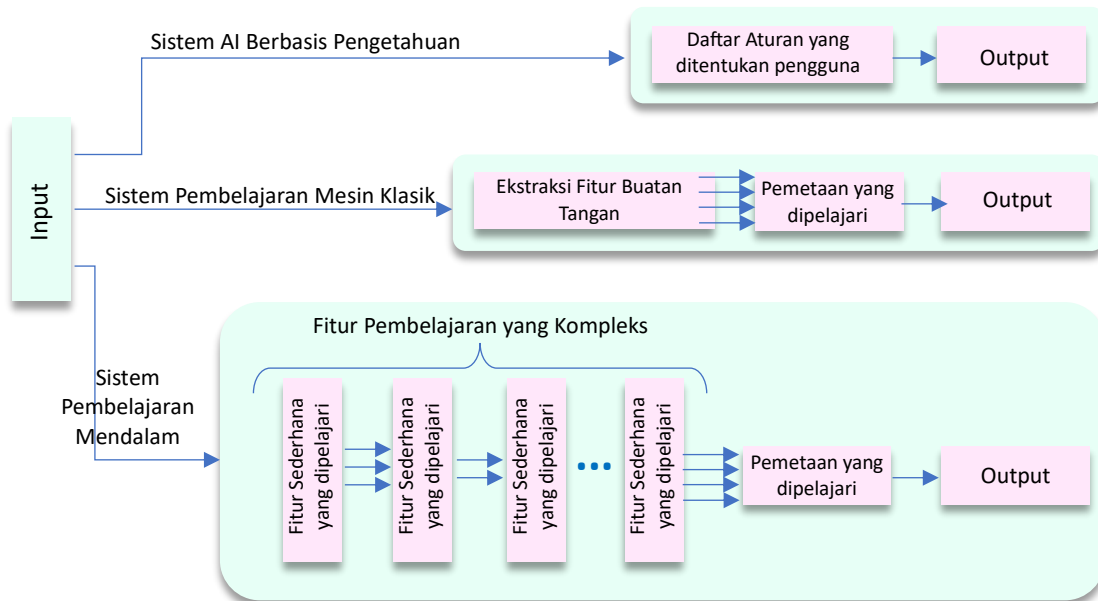
Algoritma ML standar baik supervised maupun unsupervised memerlukan prosedur ekstraksi fitur manual terlebih dahulu agar data dapat direpresentasikan dengan fitur yang telah dirancang. Keberhasilan algoritma ini sangat bergantung pada pemilihan fitur yang tepat. Oleh karena itu, penting menggunakan himpunan fitur yang mampu merepresentasikan karakteristik data masukan secara akurat. Setelah ekstraksi fitur, algoritma ML dapat lebih mudah membentuk hubungan antara keluaran dan fitur yang diekstraksi. Namun, dalam banyak tugas, menentukan himpunan fitur yang "cukup baik" bukanlah hal yang mudah.

Untuk mengatasi ketergantungan pada fitur yang dirancang secara manual dalam aplikasi AI yang rumit, dikenalkanlah metode Pembelajaran Mendalam (*Deep Learning/DL*). Algoritma DL merupakan jenis khusus dari ML yang mampu mengekstraksi representasi masukan yang dioptimalkan langsung dari data mentah, tanpa intervensi pengguna. Dari perspektif lain, metode DL tidak hanya mengekstraksi fitur, tetapi juga mempelajari korelasi antara atribut dan keluaran yang ditargetkan. Hasilnya, sistem AI yang dilatih dengan DL mampu melakukan pemetaan langsung tanpa melalui tahap ekstraksi fitur eksplisit.

Dengan demikian, DL mampu menyederhanakan fitur yang kompleks menjadi representasi yang lebih sederhana melalui proses pembelajaran, karena algoritma DL memecah tugas-tugas besar menjadi serangkaian fungsi yang lebih kecil dan mudah dikelola. Keunggulan ini telah divalidasi oleh berbagai penelitian terkini yang menunjukkan peningkatan kinerja pada masalah-masalah sulit seperti klasifikasi detak jantung, klasifikasi gambar, dan deteksi objek. Dalam konteks AI, terdapat hubungan hierarkis di mana Pembelajaran Mendalam (DL) merupakan bagian dari Pembelajaran Mesin (ML), yang sendiri merupakan subset dari Kecerdasan Buatan (AI) berbasis pengetahuan ditunjukkan pada Gambar 1.1, sementara perbandingan antara ketiga pendekatan tersebut disajikan pada Gambar 1.2.



Gambar 1.1: Hubungan antara berbagai sistem AI.



Gambar 1.2: Sistem berbasis pengetahuan, berbasis pembelajaran mesin, dan berbasis pembelajaran mesin.

1.2 JARINGAN SYARAF TIRUAN (JST)

Otak mamalia terdiri dari miliaran neuron yang saling terhubung melalui triliunan sinapsis. Jaringan pemrosesan yang masif ini memungkinkan otak menjalankan proses yang kompleks dan nonlinier secara efisien serta sangat paralel. Dengan demikian, otak dikenal memiliki keunggulan luar biasa dalam hal persepsi dan pengenalan pola bahkan melampaui kemampuan komputer digital tercanggih sekalipun.

Sebagai contoh, rata-rata manusia hanya membutuhkan waktu sekitar 100 milidetik untuk mengenali wajah orang yang dikenal di lingkungan asing, sementara komputer tercepat sekalipun memerlukan waktu lebih lama untuk melakukan tugas serupa. Kemampuan inilah yang menginspirasi para peneliti untuk mengembangkan model komputasi buatan yang terinspirasi dari interaksi, komunikasi, dan konektivitas antar neuron di otak manusia.

Jaringan Saraf Tiruan (JST) adalah model dalam pembelajaran mesin yang terinspirasi longgar dari kerangka neuron dalam sistem saraf pusat manusia. JST umumnya terdiri dari unit-unit pemrosesan nonlinier disebut juga neuron buatan yang disusun secara berlapis dan saling terhubung melalui berbagai jalur. Seperti halnya metode ML atau DL lainnya, JST mempelajari pengetahuan yang diperlukan dari kumpulan data pelatihan. Pengalaman yang dipelajari tersebut disimpan dalam bentuk interkoneksi antar neuron di dalam JST.


JST telah banyak diterapkan dalam berbagai disiplin ilmu dan rekayasa, seperti pengenalan ucapan, pengenalan pola, visi komputer, dan diagnosis medis. Dalam teknik sipil, JST telah digunakan untuk berbagai aplikasi termasuk kontrol struktural, pembuatan mesh elemen hingga, pemantauan kesehatan struktur, deteksi kerusakan struktural, serta optimasi desain. Penggunaan JST yang luas ini didorong oleh sejumlah keunggulan kemampuannya, yang dapat diringkas sebagai berikut:

1. JST sangat nonlinier, sehingga efisien dalam memprediksi perilaku sistem nonlinier yang kompleks.
2. JST merupakan model adaptif dengan kemampuan untuk mempelajari tugas-tugas yang sulit, terutama ketika data yang tersedia tidak konsisten atau fuzzy.
3. JST mampu melakukan 'generalisasi', yang berarti dapat menetapkan keluaran yang akurat untuk masukan yang belum digunakan dalam proses pelatihan.
4. Membangun model untuk sistem dengan sejumlah besar masukan dan keluaran menggunakan JST relatif mudah dibandingkan dengan metode lainnya.
5. Karena arsitektur paralelnya yang unik, JST yang diimplementasikan dalam bentuk perangkat keras tetap tangguh meskipun beberapa unit pemrosesan mengalami kegagalan.

Analogi Biologis

Sistem saraf manusia terdiri dari tiga komponen utama: reseptor, efektor, dan sistem saraf pusat. Reseptor menerjemahkan stimulus yang memengaruhi tubuh menjadi impuls listrik yang dikirim ke otak di sistem saraf pusat. "Jaringan saraf biologis" otak secara terus-menerus memproses impuls masukan dan mengirimkan impuls keluaran yang dihasilkan ke efektor untuk menghasilkan respons fisik.

Seperti ditunjukkan pada Gambar 1.3, neuron, yang merupakan blok pembangun jaringan saraf biologis ini, sebagian besar terdiri dari "badan sel" yang menaungi nukleus. Badan sel menerima sinyal dari sel lain melalui beberapa serabut saraf yang disebut dendrit. Keluaran neuron dihantarkan melalui serabut saraf yang relatif panjang yang disebut 'akson' yang bercabang menjadi sejumlah besar serabut yang mengarah ke ribuan sel lainnya. Cabang-cabang akson terhubung ke dendrit dan badan sel neuron lain pada sambungan yang disebut sinapsis. Fungsi sinapsis ini adalah untuk mengatur interaksi antar neuron.



Gambar 1.3: Ilustrasi sederhana neuron biologis.

Neuron biasanya menghasilkan keluarannya dalam bentuk rangkaian impuls tegangan yang disebut "potensial aksi". Transmisi sinyal ini ke neuron lain terjadi di sinaps melalui proses kimia yang melibatkan zat khusus bernama neurotransmitter. Pada kondisi istirahat, protoplasma di dalam badan sel bermuatan negatif, sekitar -70 mV, relatif terhadap cairan saraf di sekitarnya yang kaya ion natrium positif. Membran sel mencegah ion memasuki protoplasma, sehingga mempertahankan potensial ini. Potensial ini meningkat secara bertahap seiring dengan datangnya sinyal listrik dari neuron lain.

Ketika potensial melebihi ambang batas sekitar -60 mV, membran tiba-tiba kehilangan kemampuannya untuk menahan ion positif. Hal ini menyebabkan perubahan potensial yang drastis, sehingga badan sel melepaskan muatan atau "mengalami depolarisasi". Pelepasan muatan ini kemudian merambat sepanjang akson neuron sebagai serangkaian pulsa dengan frekuensi antara 1–100 pulsa per detik. Sinyal tersebut bergerak melalui akson dan percabangannya hingga mencapai sambungan sinaptik. Di sinaps, neurotransmitter dilepaskan dan diteruskan menuju neuron berikutnya. Neurotransmitter mengubah konduktansi sinaps pada ujung pascasinaptik, yang memengaruhi transmisi sinyal ke neuron penerima. Proses ini dapat bersifat eksitatori atau inhibitori: sinaps eksitatori mendorong neuron penerima untuk mengaktifkan potensial aksi, sementara sinaps inhibitori menekan aktivitasnya dengan menjaganya mendekati keadaan istirahat.

Seperti yang akan dijelaskan lebih detail nanti, Jaringan Saraf Tiruan (JST) terinspirasi oleh jaringan saraf biologis. Keduanya terdiri dari unit pemrosesan yang saling terhubung (neuron) dan menggunakan koneksi untuk mengelola interaksi serta menyimpan pengetahuan yang dipelajari. Namun, terdapat perbedaan signifikan antara jaringan saraf biologis dan tiruan dalam hal kompleksitas, mekanisme pemrosesan, dan cara pembelajaran terjadi :

- ❖ Neuron biologis jauh lebih lambat dibandingkan dengan chip silikon. Peristiwa saraf pada neuron biologis berlangsung dalam rentang mikrodetik, sementara chip silikon hanya membutuhkan beberapa nanodetik untuk menjalankan satu langkah program.
- ❖ Namun, otak manusia mengimbangi kecepatan lambat komponen-komponennya dengan memiliki jaringan masif yang terdiri dari sekitar 10^{11} neuron yang saling terhubung oleh hampir 10^{15} sinapsis. Di sisi lain, JST paling rumit yang pernah dirancang hanya memiliki beberapa juta interkoneksi.
- ❖ Struktur paralel otak yang sangat besar memungkinkannya untuk secara rutin menjalankan tugas klasifikasi dan pengenalan pola yang kompleks yang menantang bagi komputer.
- ❖ Berkat kemampuannya untuk menjalankan sejumlah besar operasi secara paralel, otak sangat efisien dalam hal konsumsi energi dibandingkan dengan JST.
- ❖ Biasanya, JST dirancang untuk menjalankan satu tugas khusus, sementara jaringan saraf biologis mampu mempelajari berbagai tugas yang berbeda.

Neuron Buatan

Neuron buatan adalah model matematika kasar dari neuron biologis yang membentuk unit pembangun JST. Terdapat beberapa model neuron buatan yang tersedia dalam literatur. Perseptron merupakan salah satu model neuron yang paling banyak digunakan dalam JST

umpan-maju (*feed-forward*) yang terhubung penuh, atau dikenal sebagai perseptron multilapis (*multilayer perceptron/MLP*). Seperti yang ditunjukkan pada Gambar 1.4, perseptron sederhana terdiri dari komponen-komponen berikut:

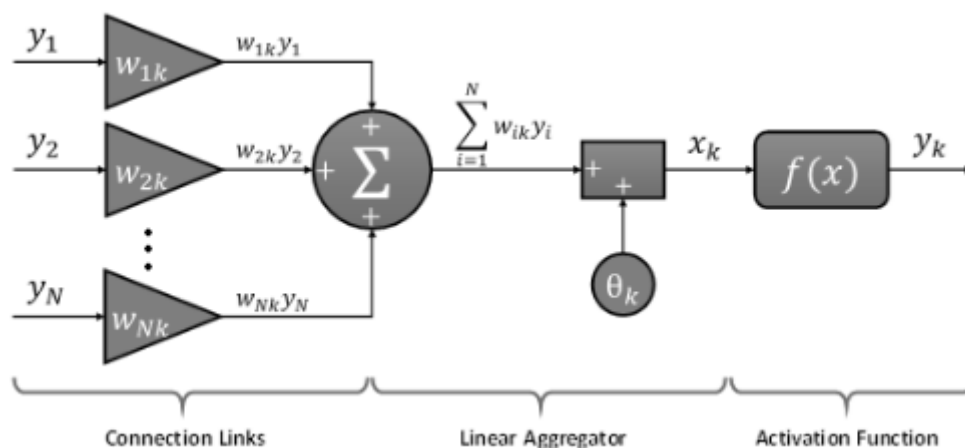
1. Tautan koneksi yang menghubungkan neuron ke neuron lain dalam jaringan. Setiap tautan diberi nomor yang disebut bobot koneksi w_{ik} , dengan subskrip i menunjukkan neuron di ujung masukan tautan, sedangkan subskrip k menunjukkan neuron di ujung penerima (yaitu, neuron saat ini). Peran bobot koneksi adalah untuk menyesuaikan masukan y , yang berasal dari neuron ke- i , sebelum diproses oleh neuron saat ini. Sebagaimana akan dijelaskan secara rinci di bagian selanjutnya, JST menyimpan pengetahuan yang diperoleh melalui pelatihan dalam bobot koneksinya.
2. Agregator linier adalah agregator yang menjumlahkan masukan terbobot dari neuron lain dengan nilai ambang θ_k yang terkait dengan neuron saat ini. Hal ini dapat dijelaskan oleh Persamaan (1.1):

$$x_k = \theta_k \sum_{i=1}^N w_{ik} y_i \quad (1.1)$$

di mana N adalah jumlah neuron yang terhubung ke neuron saat ini. Ambang batas θ_k menerapkan transformasi afin pada masukan terbobot ke neuron. Serupa dengan bobot koneksi, θ_k juga merupakan parameter yang dapat disesuaikan melalui pelatihan JST.

3. Fungsi aktivasi $f(\cdot)$ adalah fungsi yang memproses keluaran dari proses kombinasi linear x_k yang disebutkan sebelumnya untuk menghasilkan keluaran akhir neuron y_k . Proses aktivasi dapat dinyatakan sebagai Persamaan (1.2) berikut:

$$y_k = f(x_k) \quad (1.2)$$



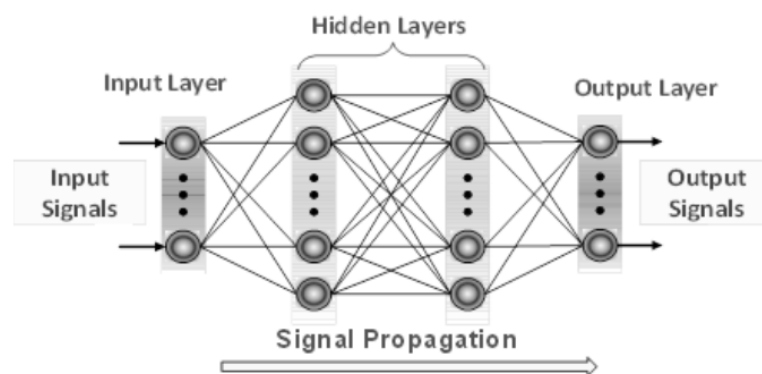
Gambar 1.4 Komponen neuron MLP.

Tugas fungsi aktivasi adalah membatasi keluaran neuron dalam rentang tertentu yang terbatas. Secara umum, fungsi aktivasi dapat dikategorikan menjadi fungsi unipolar dan bipolar. Fungsi unipolar memetakan keluaran dalam interval $[0,1]$, sementara fungsi bipolar menghasilkan keluaran dalam rentang $[-1, 1]$. Fungsi sigmoid merupakan salah satu fungsi aktivasi yang paling banyak digunakan dalam JST. Fungsi-fungsi ini halus, terdiferensiasi, dan meningkat secara ketat. Fungsi-fungsi ini menunjukkan transisi yang mulus antara perilaku linier dan nonlinier. Fungsi logistik serta fungsi tangen hiperbolik, $y = \tanh(x)$, merupakan contoh umum fungsi aktivasi sigmoid.

1.3 PERSEPTRON MULTI-LAPISAN

MLP merupakan kelas JST yang banyak digunakan. Seperti yang diilustrasikan pada Gambar 1.5, MLP terdiri dari neuron-neuron MLP yang saling terhubung dan terstruktur di dalam lapisan-lapisannya. Dalam struktur MLP, lapisan pertama disebut "lapisan masukan", sedangkan lapisan terakhir disebut "lapisan keluaran". "Lapisan tersembunyi" terletak di antara lapisan masukan dan lapisan keluaran. Sinyal masukan diterima oleh neuron masukan, kemudian diproses oleh neuron tersembunyi, dan kemudian dikirim ke neuron keluaran yang menyiarkan keluaran akhir jaringan. Perlu dicatat bahwa jaringan MLP dapat memiliki satu atau lebih lapisan tersembunyi. Jaringan yang ditunjukkan pada Gambar 1.5 memiliki dua lapisan tersembunyi hanya untuk tujuan ilustrasi. Jumlah neuron pada lapisan masukan dan keluaran ditentukan oleh jumlah masukan dan keluaran sistem yang dimodelkan. Di sisi lain, jumlah lapisan tersembunyi dan jumlah neuron pada lapisan tersembunyi merupakan 'hiperparameter' yang harus ditentukan sebelum menjalankan proses pelatihan. Parameter-parameter ini sebagian besar dipilih secara coba-coba.

Perlu dicatat bahwa MLP termasuk dalam kategori jaringan saraf tiruan multilapis, terhubung penuh, dan umpan maju karena sinyal masukan hanya diperbolehkan merambat ke arah maju. Selain itu, setiap neuron dalam setiap lapisan MLP terhubung ke neuron di lapisan sebelumnya, itulah sebabnya MLP dipandang sebagai jaringan yang terhubung sepenuhnya.



Gambar 1.5: Contoh jaringan saraf MLP.

Pelatihan MLP

MLP termasuk dalam kelas jaringan saraf tiruan terawasi, sehingga dilatih menggunakan kumpulan data yang berisi beberapa sampel masukan dengan keluaran target

yang sesuai. Sebagaimana telah dijelaskan sebelumnya, hubungan antar neuron ditetapkan oleh nilai skalar yang disebut bobot, yang berperan dalam menentukan bagaimana sinyal menyebar ke seluruh jaringan. Awalnya, bobot bersifat acak, tetapi kemudian disesuaikan selama proses pelatihan sehingga kesalahan antara keluaran aktual jaringan saraf tiruan dan target yang diinginkan diminimalkan. Pelatihan MLP merupakan proses sistematis dan iteratif yang melibatkan dua operasi: propagasi maju dan propagasi mundur.

Sesuai namanya, sampel masukan disebar ke arah maju (propagasi maju) hingga keluaran muncul dari lapisan keluaran. Keluaran ini dapat dipandang sebagai fungsi nonlinier dari masukan dalam hal bobot dan ambang batas saat ini. Fungsi biaya tertentu kemudian digunakan untuk menghitung kesalahan antara keluaran aktual jaringan saraf tiruan dan keluaran target yang sesuai dengan sampel masukan tersebut. Selanjutnya, kesalahan dipropagasi balik dari lapisan keluaran melalui lapisan tersembunyi dan akhirnya ke lapisan masukan. Selama proses propagasi balik, 'sensitivitas' setiap bobot dan ambang batas dalam jaringan terhadap kesalahan dihitung.

Sensitivitas ini digunakan untuk memperbaiki bobot dan ambang batas jaringan sesuai dengan "metode penurunan gradien". Proses propagasi maju (FP), propagasi balik, dan pembaruan bobot ini diulang hingga parameter neural (yaitu, bobot dan ambang batas) konvergen ke nilai optimal yang meminimalkan kesalahan antara keluaran aktual dan nilai target. Seluruh prosedur yang dijelaskan di bagian ini merupakan teknik optimasi yang disebut "algoritma propagasi balik", yang merupakan algoritma utama yang digunakan dalam pelatihan jaringan neural.


Algoritma Propagasi Balik dalam MLP

Jaringan MLP yang digambarkan pada Gambar 1.6 terdiri dari L lapisan (satu lapisan masukan, satu lapisan keluaran, dan $L - 2$ lapisan tersembunyi). Setiap lapisan terdiri dari N_v neuron, dengan $v = 1, 2, \dots, L$ adalah indeks lapisan. Gambar 1.6 menunjukkan gambaran lebih dekat neuron ke- k pada lapisan l yang terletak di antara lapisan $l - 1$ dan $l + 1$.

Dalam FP, neuron mengumpulkan keluaran terbobot dari lapisan $l - 1$, menjumlahkannya ke ambang batas θ_k^l , lalu menerapkan fungsi aktivasi $f(\cdot)$ pada hasil penjumlahan untuk menghitung keluaran neuron y_k^l . Operasi FP ini dapat dinyatakan dengan Persamaan (1.3, 1.4) berikut:

$$x_k^l = \theta_k^l + \sum_{i=1}^{N_{l-1}} w_{ik}^{l-1} y_i^{l-1} \quad (1.3)$$

$$y_k^l = f(x_k^l) \quad (1.4)$$



Gambar 1.6: Propagasi maju pada lapisan MLP tersembunyi.

Perhatikan bahwa superskrip pada persamaan di atas menunjukkan lapisan tempat kuantitas tersebut berada. Dengan demikian, masukan menyebar ke seluruh jaringan (neuron demi neuron) hingga vektor keluaran $Y = y_1^L, y_2^L, \dots, y_{N_L}^L$ muncul dari lapisan terakhir L . Sekarang, misalkan contoh masukan-keluaran yang digunakan dalam iterasi pelatihan ini terdiri dari masukan $P = p_1^L, p_2^L, \dots, p_{N_L}^L$, yang terkait dengan vektor target yang diinginkan $T = t_1, t_2, \dots, t_{N_L}$. Kesalahan E antara keluaran aktual dan keluaran yang diinginkan kemudian dapat dihitung berdasarkan fungsi biaya berikut seperti yang diberikan pada Persamaan (1.5):

$$E = \frac{1}{2} \sum_{i=1}^{N_L} (y_i^L - t_i)^2 \quad (1.5)$$

Faktor 1/2 diperkenalkan di sini demi kemudahan, hanya untuk menghilangkan eksponen ketika fungsi biaya didiferensiasikan terhadap y .

Tujuan algoritma backpropagation adalah mengoptimalkan bobot dan ambang batas jaringan sehingga fungsi biaya diminimalkan. Untuk ini, langkah pertama adalah mendapatkan faktor sensitivitas. Untuk neuron ke- k^{th} pada lapisan l , faktor sensitivitas yang akan dihitung adalah turunan parsial dari galat E terhadap bobot $w_{1k}, w_{2k}, \dots, w_{N_{l-1};k}$ bersama dengan ambang batas θ_l , yang dapat didefinisikan berdasarkan aturan rantai sebagai berikut Persamaan (1.6, 1.7):

$$\frac{\partial E}{\partial w_{ik}^{l-1}} = \frac{\partial E}{\partial x_k^l} \frac{\partial x_k^l}{\partial w_{ik}^{l-1}} = \frac{\partial E}{\partial x_k^l} y_i^{l-1} \quad (1.6)$$

$$\frac{\partial E}{\partial \theta_k^l} = \frac{\partial E}{\partial x_k^l} \frac{\partial x_k^l}{\partial \theta_k^l} = \frac{\partial E}{\partial x_k^l} \quad (1.7)$$

Jelas dari rumus-rumus di atas bahwa faktor sensitivitas bergantung pada turunan parsial galat seperti untuk x_k^l . Turunan parsial sering disebut sebagai "galat delta" dari neuron Δ_k^l Persamaan (1.8):

$$\Delta_k^l = \frac{\partial E}{\partial x_k^l} \quad (1.8)$$

Berdasarkan aturan rantai, kesalahan delta dari setiap neuron dapat dinyatakan sebagai Persamaan (1.9):

$$\Delta_k^l = \frac{\partial E}{\partial y_k^l} \frac{\partial y_k^l}{\partial x_k^l} = \frac{\partial E}{\partial y_k^l} f'(x_k^l) \quad (1.9)$$

Untuk neuron k di lapisan keluaran L , Persamaan (1.9) dapat dengan mudah disederhanakan menjadi Persamaan (1.10):

Namun, untuk neuron di lapisan 1 hingga $L - 1$, kita perlu mendapatkan rumus untuk menghitung turunannya $\frac{\partial E}{\partial y_k^l}$ Seperti yang diilustrasikan pada Gambar 1.6, keluaran neuron ke- k^{th} pada lapisan l (yaitu, y_k^l) berkontribusi pada masukan neuron pada lapisan berikutnya $l + 1$. Dengan demikian, dapat dibuktikan bahwa turunan kesalahan terhadap y_k^l adalah Persamaan (1.11):

$$\frac{\partial E}{\partial y_k^l} = \sum_{i=1}^{N_{l+1}} \frac{\partial E}{\partial x_k^{l+1}} \frac{\partial x_k^{l+1}}{\partial y_k^l} = \sum_{i=1}^{N_{l+1}} \Delta_i^{l+1} w_{ki}^l \quad (1.11)$$

Dengan mengganti Persamaan (1.11) ke Persamaan (1.9), kesalahan delta yang sesuai dengan neuron k apa pun di lapisan 1 hingga $L - 1$ dapat dinyatakan sebagai Persamaan (1.12):

$$\Delta_k^l = f'(x_k^l) \sum_{i=1}^{N_{l+1}} \Delta_i^{l+1} w_{ki}^l \quad (1.12)$$

Persamaan (1.12) menunjukkan bahwa galat delta, dan karenanya faktor sensitivitas, dari lapisan tertentu l bergantung pada galat delta lapisan berikutnya $l + 1$. Oleh karena itu, dalam algoritma backpropagation, kita mulai dengan menghitung galat delta lapisan keluaran L , kemudian bergerak ke arah mundur dan menghitung galat delta mulai dari lapisan tersembunyi terakhir $L - 1$ hingga tiba di lapisan masukan. Setelah galat delta dan faktor sensitivitas dihitung untuk semua neuron, bobot dan ambang batas dapat diperbarui sesuai dengan metode penurunan gradien seperti yang dinyatakan oleh Persamaan (1.13, 1.14) berikut:

$$w_{ik}^l(t+1) = w_{ik}^l(t) - \varepsilon \frac{\partial E}{\partial w_{ik}^{l-1}} \quad (1.13)$$

$$\theta_k^l(t+1) = \theta_k^l(t) - \varepsilon \frac{\partial E}{\partial \theta_k^l} \quad (1.14)$$

di mana ε disebut faktor pembelajaran. Algoritma backpropagation standar untuk pelatihan jaringan MLP dirangkum di bawah ini:

1. Pilih hiperparameter yang menentukan arsitektur JST (jumlah lapisan tersembunyi dan jumlah neuron di setiap lapisan tersembunyi).
2. Inisialisasi bobot dan ambang batas dengan bilangan acak terdistribusi seragam $U(-a, a)$.
3. Pilih sampel masukan-keluaran (atau sekumpulan sampel masukan-keluaran) dan propagasi maju masukannya melalui jaringan sesuai dengan Persamaan (1.3) dan (1.4).
4. Hitung galat antara keluaran aktual dan nilai target yang terkait dengan sampel masukan-keluaran yang dipropagasi maju seperti yang dinyatakan oleh Persamaan (1.5).
5. Hitung galat delta lapisan keluaran sesuai dengan Persamaan (1.10).
6. Hitung galat delta lapisan lainnya mulai dari lapisan tersembunyi $L - 1$ hingga lapisan masukan sesuai dengan Persamaan (1.12).
7. Dapatkan faktor sensitivitas seperti yang dijelaskan oleh Persamaan (1.6), (1.7), dan (1.8).
8. Terapkan metode penurunan gradien untuk memperbarui bobot dan ambang batas sesuai dengan Persamaan (1.13) dan (1.14).
9. Ulangi langkah 3 hingga 8 untuk setiap sampel (atau batch sampel) dalam set data pelatihan.
10. Ulangi langkah 3 hingga 9 untuk sejumlah epoch yang cukup hingga kriteria penghentian tertentu terpenuhi. Satu epoch didefinisikan sebagai satu siklus lengkap dari set data pelatihan yang dijelaskan.

Pelatihan Batch vs. Pelatihan Daring

Dua pendekatan backpropagation umum dapat digunakan untuk melatih ANN. Perbedaan antara kedua pendekatan ini hanya terletak pada cara bobot dan ambang batas ANN diperbarui. Dalam pendekatan pertama, yang disebut pelatihan daring, parameter ANN diperbarui untuk setiap sampel masukan-keluaran. Oleh karena itu, untuk dataset yang terdiri dari n sampel pelatihan, jaringan diperbarui n kali untuk setiap periode pelatihan.

Hal ini dapat direpresentasikan oleh pseudocode berikut:

```
for each training epoch, DO:
    for each input-output sample, DO:
```

```
    compute the sensitivity factors for the current sample
    update the weights and thresholds using the sensitivity factors
  end for
end for
```

Dalam pendekatan kedua, yang biasanya disebut "pelatihan batch", seluruh dataset dipropagasi maju dan mundur melalui jaringan, dan semua faktor sensitivitas diakumulasikan lalu digunakan untuk memperbarui jaringan. Dengan demikian, parameter jaringan hanya diperbarui sekali per epoch sebagaimana dijelaskan oleh pseudocode berikut:

```
for each training epoch, DO:
  for each input-output sample, DO:
    compute the sensitivity factors for the current sample
    accumulate the sensitivity factors
  end for
  update the weights and thresholds using the accumulated sensitivity factors
end for
```


Pelatihan daring umumnya lebih mudah diimplementasikan dan lebih efisien daripada pelatihan batch dalam menangani masalah klasifikasi yang menantang (Haykin, 2008). Di sisi lain, pelatihan batch memparalelkan proses pelatihan ANN karena faktor sensitivitas untuk setiap sampel dapat dihitung secara paralel (yaitu, independen dari sensitivitas sampel lainnya). Hal ini dapat meningkatkan kecepatan pelatihan secara drastis saat menggunakan CPU multi-inti.

Inisialisasi Acak

Sebagaimana telah disebutkan sebelumnya, langkah pertama dalam melatih jaringan MLP adalah menetapkan bobot koneksinya secara acak. Bobot tersebut kemudian disesuaikan dengan menerapkan algoritma backpropagation pada set data pelatihan. Investigasi pada jaringan MLP dalam (yaitu, MLP dengan banyak lapisan tersembunyi) menunjukkan bahwa proses pelatihan dapat dipengaruhi secara negatif oleh fenomena "gradien yang menghilang". Fenomena ini sangat bergantung pada bobot acak awal dan jenis fungsi aktivasi yang digunakan dalam neuron MLP. Untuk memahami fenomena ini, perhatikan fungsi aktivasi sigmoid yang ditunjukkan pada Gambar 1.7.

Sebuah neuron disebut 'jenuh' ketika masukan ke fungsi aktivasinya mendekati ujung ekstrem. Ketika neuron mencapai saturasi, terlihat jelas dari plot bahwa turunan dari fungsi aktivasi mendekati nol. Ketika melatih jaringan dalam yang diinisialisasi secara tidak tepat, sangat mungkin neuron pada lapisan tersembunyi terakhir akan cepat jenuh, yang menyebabkan gradien yang kecil. Ketika melakukan backpropagasi gradien kecil ini melalui lapisan-lapisan jaringan, gradien tersebut menjadi semakin kecil hingga menghilang

sempurnya pada beberapa lapisan pertama. Hal ini dapat menyebabkan kinerja pelatihan yang buruk karena lapisan tersembunyi pertama dari ANN dalam biasanya bertanggung jawab atas proses ekstraksi fitur.



Gambar 1.7: Fungsi aktivasi sigmoid dan turunannya.

Glorot dan Bengio menyelidiki hubungan antara inisialisasi bobot dan fenomena gradien yang menghilang untuk beberapa jenis fungsi aktivasi. Mereka menunjukkan secara statistik bahwa fenomena tersebut dapat dihindari dengan menginisialisasi jaringan dalam sesuai dengan rumus yang diberikan pada Tabel 1.1.

Tabel 1.1: Rumus yang direkomendasikan untuk inisialisasi bobot.

Fungsi Aktivasi	Distribusi Seragam $U(-a, a)$
tanh	$a = 4 \sqrt{\frac{6}{n_i + n_o}}$
Fungsi Logic	$a = \sqrt{\frac{6}{n_i + n_o}}$

Catatan: Notasi n_i menunjukkan jumlah neuron pada lapisan sebelumnya, sementara n_o menunjukkan jumlah neuron pada lapisan berikutnya.

Overfitting vs. Generalisasi

Pelatihan jaringan saraf tiruan dengan backpropagation dapat dipandang sebagai masalah pencocokan kurva nonlinier yang bertujuan untuk mendapatkan pemetaan yang tepat dari masukan dataset pelatihan ke target terkait. Dalam beberapa kasus, ketika arsitektur ANN yang dipilih terlalu kompleks atau ketika hanya sedikit sampel pelatihan yang digunakan, proses pelatihan dapat menyebabkan jaringan saraf tiruan overfitting. Overfitting, yang merupakan kebalikan dari generalisasi, menyiratkan bahwa ANN hanya dapat menangani sampel masukan yang tepat yang digunakan selama proses pelatihan.

Menggunakan ANN overfitting untuk memprediksi keluaran sampel masukan yang sedikit berbeda dari sampel pelatihan dapat menghasilkan hasil yang salah. Overtraining

menyebabkan ANN menyesuaikan kurva dengan derau dalam data pelatihan, alih-alih mempelajari proses yang mendasarinya. Oleh karena itu, sangat penting untuk memeriksa kemampuan ANN yang terlatih untuk melakukan generalisasi. Untuk melakukannya, data biasanya dibagi menjadi set data pelatihan dan validasi. Di antara set data ini, set data pelatihan digunakan untuk melatih jaringan, sementara set validasi digunakan setelahnya untuk menguji jaringan terhadap overfitting.

1.4 JARINGAN SARAF TIRUAN KONVOLUSIONAL (CNN)

CNN merupakan jenis *Artificial Neural Network* (ANN) umpan-maju berlapis banyak yang bekerja secara tersupervisi. Seperti telah disinggung sebelumnya, struktur dan organisasi CNN terinspirasi oleh model sel sederhana dan kompleks pada korteks visual primer otak mamalia. Belakangan ini, CNN telah menjadi standar dalam berbagai prosedur pembelajaran berbasis data (*deep learning*), seperti klasifikasi basis data gambar berskala besar dan pengenalan wajah. Keunggulan ini disebabkan oleh kemampuannya yang inheren untuk menggabungkan operasi ekstraksi fitur dan klasifikasi fitur ke dalam satu kerangka pembelajaran yang terpadu. Ciri penting lain dari CNN adalah kemampuannya untuk mengklasifikasikan gambar secara robust tanpa terpengaruh oleh variasi skala maupun orientasi.

Operasi Konvolusi


Sesuai namanya, Convolutional Neural Network (CNN) terutama bergantung pada operasi matematika yang disebut konvolusi. Dalam terminologi CNN, sebuah input I dikonvolusikan dengan sebuah filter atau *kernel* 2D w untuk menghasilkan peta fitur S . Untuk input 2D (seperti gambar), operasi konvolusi standar dalam CNNs, yang dilambangkan dengan operator (*), dapat dinyatakan dengan rumus berikut:

$$I * w = S(i, j) = \sum_m \sum_n I(i + m, j + n)w(m, n) \quad (1.15)$$


Persamaan di atas diilustrasikan secara grafis pada Gambar 1.8. Seperti yang ditunjukkan pada gambar, konvolusi standar dilakukan dengan menggeser filter di dalam batas-batas citra masukan secara piksel demi piksel. Oleh karena itu, setiap piksel dalam peta fitur keluaran berkorespondensi dengan lokasi kernel tertentu di atas citra masukan. Karena kernel tidak diperbolehkan melewati tepi citra, konvolusi standar mengurangi dimensi citra sebesar $K_x - 1, K_y - 1$, di mana K_x dan K_y adalah dimensi kernel yang diterapkan. Pada Gambar 1.8 misalnya, citra masukan 4×4 direduksi menjadi peta fitur 3×3 . Dalam beberapa kasus, ukuran citra harus tetap tidak berubah setelah konvolusi. Inilah sebabnya mengapa zero-padding terkadang diterapkan dengan menambahkan $(K_x - 1, K_y - 1)$ angka nol pada batas-batas citra sebelum konvolusi. Operasi ini, yang digambarkan pada Gambar 1.9, biasanya disebut "konvolusi penuh".

Struktur CNN

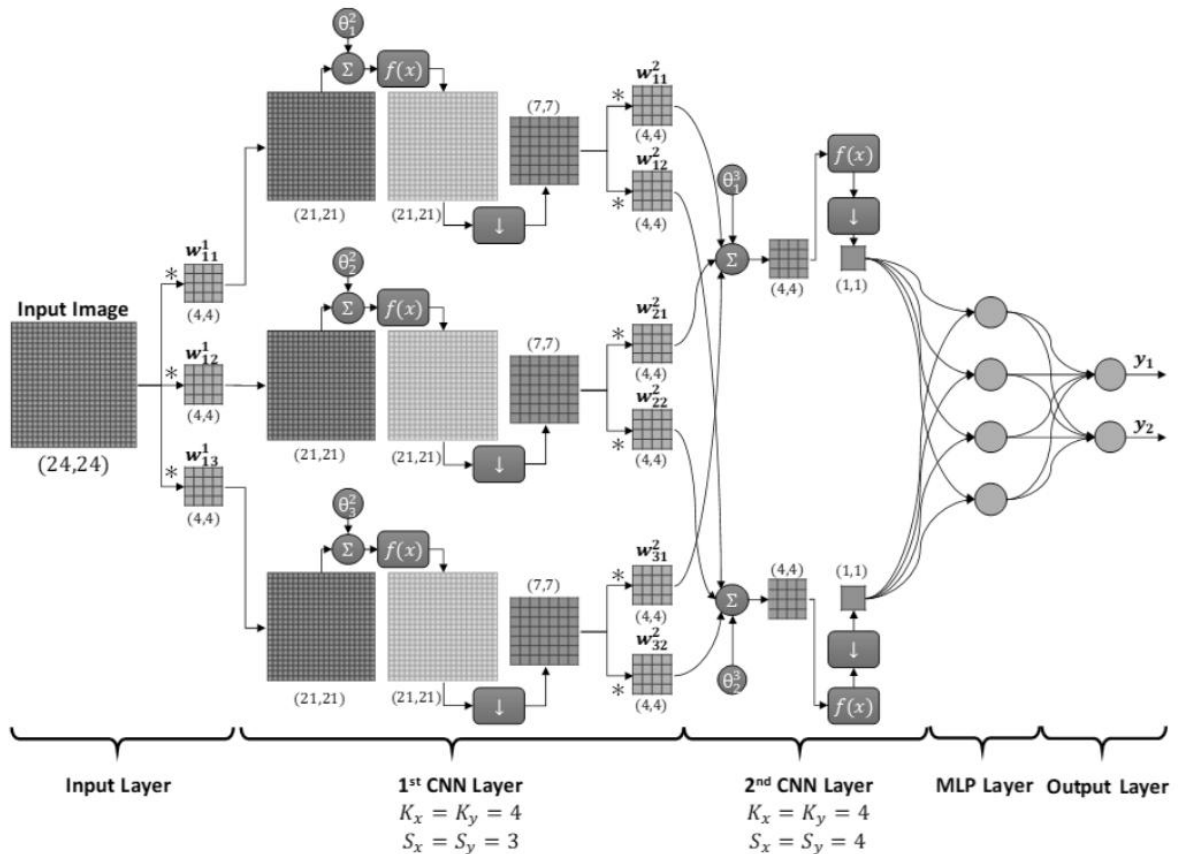
Untuk menjelaskan struktur CNN, Gambar 1.10 menunjukkan contoh CNN yang digunakan untuk mengklasifikasikan citra skala abu-abu 24x24 piksel menjadi dua kategori.



Gambar 1.8: Konvolusi standar tanpa zero-padding.



Gambar 1.9: Konvolusi penuh dengan bantalan nol.



Gambar 1.10: Contoh struktur CNN.

Lapisan pertama (yaitu, lapisan masukan) terdiri dari satu neuron yang menerima citra 24×24 . Lapisan masukan diikuti oleh sejumlah neuron konvolusional yang saling terhubung dan tersusun dalam dua lapisan CNN tersembunyi. Keluaran dari lapisan-lapisan CNN diproses oleh satu lapisan tersembunyi MLP dan terakhir oleh lapisan keluaran.

Setiap neuron konvolusional ditetapkan oleh ukuran kernel tertentu (K_x, K_y) , faktor subsampling (S_x, S_y) , ambang batas θ , dan fungsi aktivasi f . Selain itu, setiap interkoneksi antar lapisan CNN ditetapkan kernel $K_x \times K_y$ (yaitu, bobot), w . Dalam contoh ini, ukuran kernel untuk semua neuron ditetapkan sebagai $K_x = K_y = 4$, sedangkan faktor subsampling dipilih sebagai $S_x = S_y = 3$ untuk lapisan konvolusional pertama, dan $S_x = S_y = 4$ untuk lapisan kedua. Perhatikan bahwa nilai-nilai ini sengaja dipilih agar keluaran lapisan CNN terakhir (yaitu, masukan ke lapisan MLP pertama) berupa skalar.

Namun, jumlah lapisan tersembunyi MLP beserta jumlah neuron di lapisan CNN dan MLP dipilih secara acak hanya untuk tujuan ilustrasi. Lapisan keluaran terdiri dari dua neuron MLP yang sesuai dengan jumlah kelas yang dikategorikan pada gambar. Langkah-langkah berikut menjelaskan proses FP lengkap dalam contoh CNN ini:

1. Citra skala abu-abu berukuran 24×24 piksel diterima oleh neuron masukan.
2. Neuron masukan mengirimkan citra tersebut ke tiga neuron di lapisan CNN pertama.
3. Setiap neuron di lapisan CNN pertama menerapkan operasi konvolusi standar (yaitu, tanpa zero-padding) antara citra dan kernel pembobot terkait, menghasilkan peta fitur berukuran 21×21 .

4. Neuron CNN kemudian menjumlahkan peta fitur tersebut ke suatu ambang batas dan kemudian menerapkan fungsi aktivasi.
5. Keluaran fungsi aktivasi (21×21) didesimasi dengan faktor subsampling 3, menghasilkan peta berukuran 7×7 .
6. Keluaran dari tiga neuron di lapisan CNN tersembunyi pertama dikirim ke lapisan kedua. Oleh karena itu, setiap neuron di lapisan CNN kedua menerima tiga peta masukan.
7. Demikian pula, setiap neuron menerapkan konvolusi standar antara setiap peta masukan dan kernelnya yang sesuai, menghasilkan tiga peta fitur 4×4 .
7. Ketiga peta fitur tersebut dijumlahkan dengan ambang batas. Keluaran dari penjumlahan tersebut diaktifkan oleh fungsi aktivasi.
8. Keluaran yang diaktifkan (4×4) didesimasi dengan faktor subsampling 4, menghasilkan keluaran 1×1 (yaitu, skalar).
9. Keluaran skalar dari lapisan CNN terakhir dipropagasi maju melalui lapisan MLP dan lapisan keluaran berikutnya sebagaimana dijelaskan di Bagian 2.3 untuk menghasilkan keluaran akhir yang merepresentasikan klasifikasi citra masukan.

Dari contoh ini, kesimpulan berikut dapat ditarik mengenai struktur dan komponen CNN:

- CNN terdiri dari sejumlah lapisan CNN tersembunyi yang biasanya, tetapi tidak selalu, diikuti oleh beberapa lapisan MLP.
- Neuron konvolusional dalam lapisan CNN mampu melakukan operasi konvolusi, agregasi, aktivasi, dan subsampling standar.
- Struktur CNN ditentukan oleh hiperparameter berikut:
 - Jumlah lapisan tersembunyi CNN dan MLP.
 - Jumlah neuron di setiap lapisan tersembunyi.
 - Ukuran kernel (K_x, K_y) dan faktor subsampling (S_x, S_y) untuk neuron konvolusional.
- Dalam FP, ukuran citra masukan dikurangi secara bertahap melalui operasi konvolusi dan subsampling yang berurutan. Jumlah lapisan CNN tersembunyi beserta ukuran kernel dan faktor subsampling setiap lapisan harus dipilih sedemikian rupa sehingga menghasilkan keluaran skalar pada lapisan CNN terakhir.

Keunggulan CNN

Pada Gambar 1.10, setiap neuron konvolusional pada lapisan CNN tersembunyi pertama terhubung ke citra masukan oleh satu kernel yang hanya terdiri dari bobot $3 \times 3 = 9$. Sekarang, misalkan jaringan MLP biasa digunakan untuk mengklasifikasikan citra yang sama, alih-alih CNN. Dalam hal ini, lapisan masukan akan memiliki 24×24 neuron untuk menerima piksel citra. Sebagaimana dijelaskan pada Bagian 2.3, karena jaringan MLP terhubung penuh, setiap neuron pada lapisan tersembunyi pertama akan memiliki $24 \times 24 = 576$ koneksi ke lapisan masukan yang ditetapkan oleh 576 bobot skalar.

Contoh ini menunjukkan perbedaan signifikan antara CNN dan jaringan MLP terhubung penuh dalam hal jumlah parameter yang perlu disetel selama proses pelatihan. Hal ini disebabkan oleh fakta bahwa lapisan CNN terhubung jarang, yang berarti keluaran neuron CNN

hanya berkorelasi dengan sebagian kecil peta masukan. Lebih lanjut, jelas bahwa dalam operasi konvolusi standar di dalam neuron CNN, kernel yang sama digunakan di seluruh gambar.

Oleh karena itu, alih-alih mempelajari bobot individual untuk setiap piksel gambar (seperti dalam MLP), neuron CNN hanya mempelajari sekumpulan kecil parameter dan menerapkannya di seluruh peta masukan. Memiliki parameter bersama, atau dengan kata lain, "bobot terikat" secara signifikan mengurangi memori dan waktu komputasi yang diperlukan untuk menjalankan proses pelatihan dan memungkinkan implementasi paralel CNN.

Lebih lanjut, proses subsampling memungkinkan neuron CNN untuk mengekstrak fitur yang invarian terhadap translasi dan distorsi kecil. Hal ini khususnya penting ketika tujuannya adalah untuk mendeteksi fitur tertentu, alih-alih menemukan lokasi persisnya. Proses subsampling juga memungkinkan CNN untuk memproses gambar dengan ukuran berbeda hanya dengan mengubah faktor subsampling yang sesuai.

Singkatnya, keuntungan utama penggunaan CNN dalam aplikasi pembelajaran jarak jauh adalah:

1. CNN memiliki kemampuan untuk menggabungkan tahap ekstraksi fitur dan klasifikasi fitur menjadi satu model. Mereka dapat mempelajari fitur apa yang harus diekstrak dan cara mengklasifikasikan fitur-fitur ini langsung dari masukan mentah.
2. Karena neuron CNN terhubung secara jarang dengan bobot yang terikat, mereka dapat beroperasi dengan masukan besar dengan efisiensi komputasi yang unggul.
3. CNN kebal terhadap transformasi kecil pada data masukan, termasuk distorsi, skewing, penskalaan, dan translasi.
4. CNN dapat beradaptasi dengan berbagai ukuran masukan.

Algoritma Backpropagation dalam CNN

Serupa dengan MLP, CNN dilatih secara terawasi menggunakan kumpulan data sampel masukan-keluaran. Masukannya berupa gambar (atau kanal warna dari gambar), sedangkan keluarannya berupa vektor kelas yang sesuai dari gambar masukan tersebut. Pada contoh yang ditunjukkan pada Gambar 1.11, vektor keluaran dapat berupa [1 0] yang menunjukkan bahwa gambar tersebut termasuk dalam kelas 1, atau [0 1] jika gambar tersebut termasuk dalam kelas 2. Bagian ini menjelaskan algoritma backpropagation yang digunakan untuk melatih CNN menggunakan kumpulan data pelatihan.

Misalnya sebuah CNN yang terdiri dari L lapisan (lapisan masukan + lapisan keluaran + L_a lapisan CNN tersembunyi + L_b lapisan MLP tersembunyi). Setiap lapisan terdiri dari N_v neuron, dengan $v = 1, 2, \dots, L$ adalah indeks lapisan. Gambar 1.12 menunjukkan tampilan lebih dekat pada lapisan CNN tersembunyi l yang terletak di antara dua lapisan CNN, $l - 1$ dan $l + 1$. Dalam FP, citra masukan pertama-tama disebarkan melalui lapisan CNN tersembunyi. Operasi FP dari lapisan CNN $l - 1$ ke neuron ke- k pada lapisan l dapat ditulis sebagai Persamaan (1.16, 1.17, 1.18):

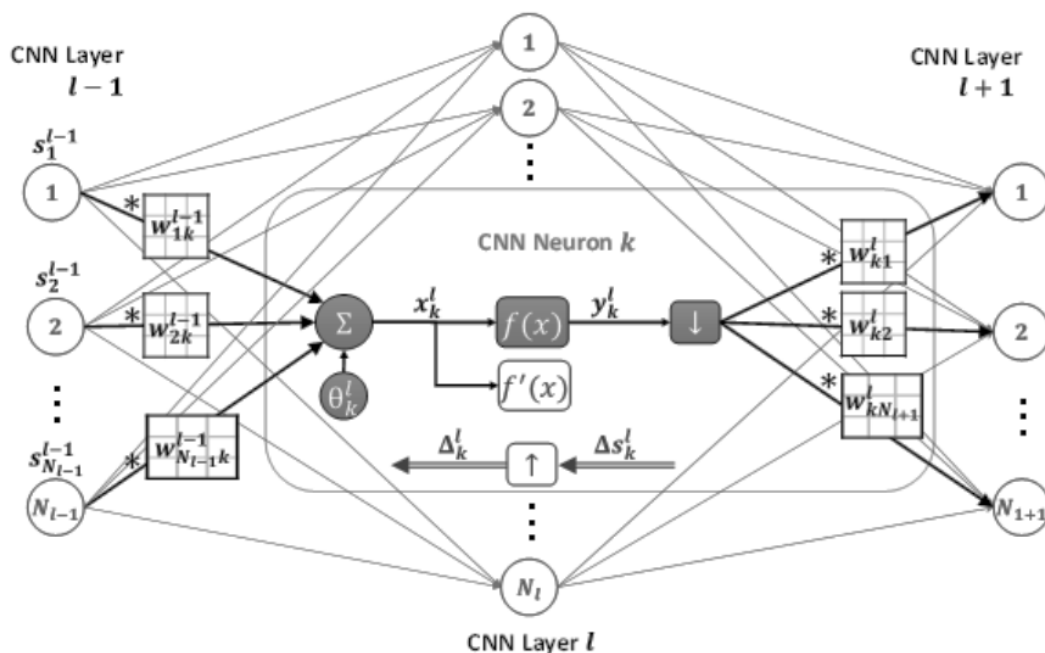
$$x_k^l = b_k^l + \sum_{i=1}^{N_{i-1}} \text{Conv}(w_{ik}^{l-1}, s_i^{l-1}) \quad (1.16)$$

$$y_k^l = f(x_k^l) \quad (1.17)$$

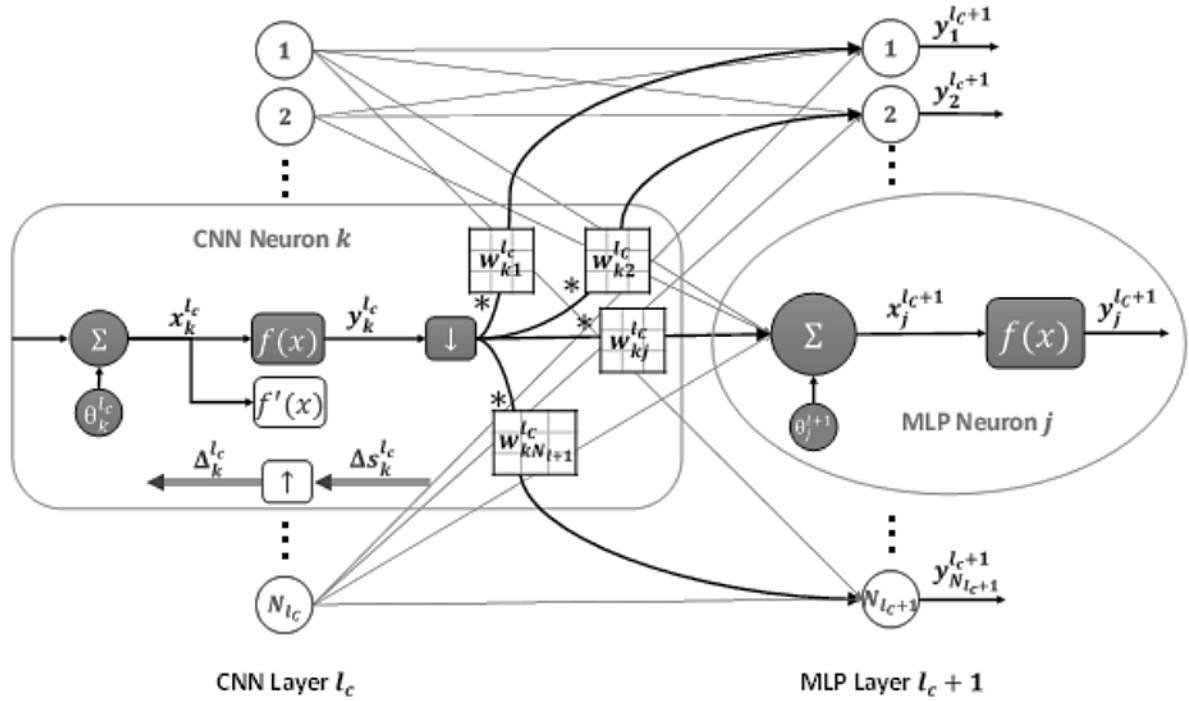
$$s_k^l = \text{down}_{(S_x, S_y)}(y_k^l) \quad (1.18)$$

di mana operator $\text{Conv}(\cdot)$ menunjukkan operasi konvolusi standar (yaitu, tanpa zero-padding), w_{ik}^{l-1} menunjukkan bobot kernel yang menghubungkan neuron ke- k pada lapisan l ke neuron ke- i pada lapisan $l - 1$, s_i^{l-1} adalah keluaran dari neuron ke- i pada lapisan $l - 1$, s_k^l adalah keluaran akhir dari neuron ke- k pada lapisan l , dan b_k^l adalah ambang batas yang terkait dengan neuron saat ini. Operator $\text{down}_{(S_x, S_y)}$ merepresentasikan operasi down-sampling dengan pengumpulan rata-rata menurut faktor subsampling S_x dan S_y . Perhatikan bahwa superskrip pada persamaan di atas menunjukkan lapisan tempat kuantitas tersebut berada.

Sebagaimana telah disebutkan sebelumnya, ukuran kernel (K_x, K_y) dan faktor subsampling (S_x, S_y) dari lapisan CNN tersembunyi harus dipilih dengan cermat agar keluaran dari lapisan CNN terakhir berupa skalar. Keluaran skalar ini kemudian disebarakan melalui MLP sesuai dengan Persamaan (1.3) dan (1.4) hingga muncul vektor keluaran $Y = y_1^L, y_2^L, \dots, y_{N_L}^L$ dari lapisan keluaran L . Dengan asumsi bahwa citra masukan yang digunakan dalam operasi FP ini dikaitkan dengan vektor target yang diinginkan $T = t_1, t_2, \dots, t_{N_L}$, kesalahan antara keluaran aktual dan keluaran yang diinginkan E dapat dihitung menurut fungsi biaya yang didefinisikan dalam Persamaan (1.5).



Gambar 1.11 Propagasi maju dan propagasi mundur dalam lapisan CNN tersembunyi.



Gambar 1.12: Propagasi maju dan propagasi mundur antara lapisan CNN tersembunyi terakhir dan lapisan MLP tersembunyi pertama.

Langkah selanjutnya adalah melakukan backpropagasi (BP) kesalahan ini dari lapisan keluaran melalui lapisan MLP tersembunyi, kemudian lapisan CNN, dan akhirnya ke lapisan masukan. Selama proses BP ini, faktor sensitivitas setiap bobot dan ambang batas dalam jaringan terhadap kesalahan dihitung. Delta kesalahan dan faktor sensitivitas lapisan keluaran dan lapisan MLP tersembunyi dapat dengan mudah dihitung seperti yang dijelaskan sebelumnya dalam Persamaan (1.6), (1.7), (1.8), (1.10), (1.12).

Setelah itu, kesalahan dipropagasi balik dari lapisan MLP pertama $l_c + 1$ ke lapisan CNN terakhir l_c . Gambar 1.12 menunjukkan hubungan antara neuron ke- j pada lapisan $l_c + 1$ dan neuron ke- k pada lapisan l_c . Galat delta $\Delta S_k^{l_c}$ yang di-down-sampling dari neuron CNN pada lapisan CNN tersembunyi terakhir l_c dapat dihitung berdasarkan kernel terkait $w_{ki}^{l_c}$ beserta galat delta lapisan MLP pertama $l_c + 1$ sebagai berikut Persamaan (1.19) (Kiranyaz dkk., 2016):

$$\Delta S_k^{l_c} = \frac{\partial E}{\partial S_k^{l_c}} = \sum_{i=1}^{N_{l_c+1}} \frac{\partial E}{\partial x_i^{l_c+1}} \frac{\partial x_i^{l_c+1}}{\partial S_k^{l_c}} = \sum_{i=1}^{N_{l_c+1}} \Delta_i^{l_c} w_{ki}^{l_c} \quad (1.19)$$

Kemudian, seperti yang diberikan pada Persamaan (1.20) kesalahan delta yang diturunkan sampelnya ini dapat digunakan untuk menghitung kesalahan delta $\Delta_i^{l_c}$:

$$\Delta_i^{l_c} = \frac{1}{S_x S_y} \text{up}_{(S_x, S_y)} \Delta S_k^{l_c} f'(x_k^{l_c}) \quad (1.20)$$

di mana operator $up_{(S_x, S_y)}$ merepresentasikan operasi up-sampling dengan faktor S_x dan S_y . Perhatikan bahwa eksponen $\frac{1}{S_x S_y}$ diperkenalkan di sini karena, menurut Persamaan (1.17), setiap piksel dalam $s_k^{l_c}$ keluaran dihitung dengan merata-ratakan piksel S dari keluaran fungsi aktivasi $y_k^{l_c}$.

Untuk neuron CNN di lapisan CNN lainnya (lapisan 1 hingga $l_c - 1$), dapat ditunjukkan bahwa galat delta down-sampling Δs_k^l dan galat delta Δ_k^l dari neuron di lapisan tersembunyi CNN l diberikan dalam Persamaan (1.21, 1.22) (Kiranyaz dkk., 2016):

$$\Delta s_k^l = \sum_{i=1}^{N_{i+1}} \text{ConvZ}(\Delta_i^{l+1}, \text{rot180}(w_{ki}^l)) \quad (1.21)$$

$$\Delta_k^l = \frac{1}{S_x S_y} up_{(S_x, S_y)}(\Delta s_k^l) f'(x_k^l) \quad (1.22)$$

di mana $\text{ConvZ}(\cdot)$ merepresentasikan operasi konvolusi penuh (yaitu, dengan $K_x - 1, K_y - 1$ zero-padding), Δ_i^{l+1} adalah galat delta lapisan CNN berikutnya, w_{ki}^l adalah kernel yang terkait dengan neuron saat ini, f' adalah turunan fungsi aktivasi, dan operator $\text{rot180}(\cdot)$ merepresentasikan operasi rotasi matriks 180° .

Dengan menggunakan galat delta yang dihitung oleh Persamaan (1.20) dan (1.22), faktor sensitivitas semua neuron dalam jaringan (termasuk neuron lapisan CNN terakhir l_c) dapat diperoleh sebagai Persamaan (1.23, 1.24):

$$\frac{\partial E}{\partial w_{ki}^l} = \text{conv}(s_k^l, \Delta_i^{l+1}) \quad (1.23)$$

$$\frac{\partial E}{\partial \theta_{ki}^l} = \sum_m \sum_n \Delta_k^l(m, n) \quad (1.24)$$

di mana m dan n adalah dimensi matriks Δ_k^l . Akhirnya, setelah galat delta dan faktor sensitivitas dihitung untuk semua neuron, bobot dan ambang batas dapat diperbarui sesuai dengan metode penurunan gradien seperti yang dinyatakan dalam Persamaan (1.13) dan (1.14). Algoritma backpropagation untuk pelatihan CNN dapat diringkas dalam langkah-langkah berikut:

1. Pilih hiperparameter yang menentukan arsitektur CNN:
 - a. Jumlah lapisan CNN tersembunyi.
 - b. Jumlah lapisan MLP tersembunyi.
 - c. Jumlah neuron di setiap lapisan tersembunyi.
 - d. Ukuran kernel setiap lapisan (K_x, K_y) .
 - e. Faktor subsampling setiap lapisan (S_x, S_y) .

2. Inialisasi kernel, bobot, dan ambang batas dengan bilangan acak terdistribusi seragam $U(-a, a)$.
3. Pilih sampel masukan-keluaran (atau sekumpulan sampel masukan-keluaran untuk kasus pelatihan batch).
4. Propagasi maju masukan sampel yang dipilih melalui lapisan CNN sesuai dengan Persamaan (1.16–1.18).
5. Propagasi maju keluaran lapisan CNN terakhir melalui lapisan MLP sesuai dengan Persamaan (1.3) dan (1.4).
6. Hitung galat antara keluaran aktual dan target yang diinginkan yang terkait dengan sampel masukan-keluaran yang dipropagasi maju seperti yang dinyatakan oleh Persamaan (1.5).
7. Hitung galat delta lapisan keluaran sesuai dengan Persamaan (1.10).
8. Hitung galat delta lapisan MLP mulai dari lapisan $L - 1$ hingga lapisan MLP pertama $l_c + 1$ sesuai dengan Persamaan (1.2). (1.12).
9. Hitung galat delta lapisan CNN terakhir l_c menurut Persamaan (1.19) dan (1.20).
10. Hitung galat delta lapisan CNN yang tersisa mulai dari lapisan $l_c - 1$ hingga lapisan masukan menurut Persamaan (1.21) dan (1.22).
11. Dapatkan faktor sensitivitas lapisan MLP sebagaimana dijelaskan oleh Persamaan (1.6), (1.7), dan (1.8).
12. Dapatkan faktor sensitivitas lapisan CNN sebagaimana dijelaskan oleh Persamaan (1.23) dan (1.24).
13. Terapkan metode penurunan gradien untuk memperbarui bobot dan ambang batas menurut Persamaan (1.13) dan (1.14).
14. Ulangi langkah 3 hingga 13 untuk setiap sampel (atau kumpulan sampel untuk kasus pelatihan batch) dalam set data pelatihan.
15. Ulangi langkah 3 hingga 14 untuk jumlah epoch yang memadai hingga kriteria penghentian tertentu terpenuhi. Satu epoch didefinisikan sebagai satu lintasan lengkap dari keseluruhan dataset pelatihan.

Jaringan Saraf Tiruan Konvolusional Satu Dimensi

CNN yang dijelaskan sejauh ini dirancang untuk berjalan hanya pada data 2D seperti video dan gambar. Oleh karena itu, CNN ini dikenal sebagai CNN 2D. Meskipun demikian, telah ada beberapa upaya untuk menerapkan CNN 2D guna menangani sinyal 1D alami. Berbagai teknik telah diusulkan untuk merepresentasikan data 1D dalam bentuk 2D, termasuk membentuk ulang larik masukan menjadi matriks dan menggabungkan beberapa sinyal 1D menjadi 'gambar' 2D.

Sebagai alternatif, versi modifikasi CNN 2D telah dikembangkan untuk berjalan pada aplikasi satu dimensi. Versi yang dimodifikasi disebut Jaringan Saraf Tiruan Konvolusional Satu Dimensi (1D CNNs). CNN 1D secara umum mirip dengan versi 2D-nya, kecuali beberapa perbedaan struktural. Kernel pembobot CNN 1D adalah array 1D (bukan kernel 2D pada CNN 2D). Oleh karena itu, semua operasi FP dan BP 2D yang dijelaskan di Bagian 4.3 harus

digantikan oleh padanan 1D-nya. Selain itu, hiperparameter 2D (K_x, K_y) dan (S_x, S_y) digantikan oleh skalar tunggal K dan S . Akibatnya, Persamaan (1.25–1.27) untuk operasi FP pada CNN 1D dapat dinyatakan sebagai berikut:

$$x_k^l = b_k^l + \sum_{i=1}^{N_{l-1}} \text{convID}(w_{ik}^{l-1}, s_i^{l-1}) \quad (1.25)$$

$$y_k^l = f(x_k^l) \quad (1.26)$$

$$s_k^l = \text{down}_s(y_k^l) \quad (1.27)$$

di mana $\text{conv1D}(\cdot)$ merepresentasikan operasi konvolusi 1D standar yang dilakukan dengan menggeser larik kernel w_{ik}^{l-1} di atas larik s_i^{l-1} tanpa zero-padding, dan $\text{down}_s(\cdot)$ merepresentasikan operasi down-sampling dengan pengumpulan rata-rata berdasarkan faktor subsampling S .

Selain itu, Persamaan BP (1.28–1.31) untuk menghitung delta dan faktor sensitivitas lapisan CNN dalam CNN 1D adalah sebagai berikut:

$$\Delta s_k^l = \sum_{i=1}^{N_{l-1}} \text{convIDz}[\Delta_i^{l-1}, \text{rev}(s_i^{l-1})] \quad (1.28)$$

$$\Delta_k^l = \frac{1}{2} \text{up}_s(\Delta s_k^l) f'(x_k^l) \quad (1.29)$$

$$\frac{\partial E}{\partial w_{ki}^l} = \text{convID}(s_k^l, \Delta_i^{l+1}) \quad (1.30)$$

$$\frac{\partial E}{\partial \theta_{ki}^l} = \sum_n \Delta_k^l(n) \quad (1.31)$$

di mana $\text{conv1Dz}(\cdot)$ merepresentasikan operasi konvolusi 1D penuh dengan $K - 1$ zero-padding, $\text{rev}(\cdot)$ merepresentasikan operasi pembalikan array, $\text{up}_s(\cdot)$ adalah operasi up-sampling dengan faktor S , dan n adalah jumlah elemen dalam array Δ_k^l .

Dapat dilihat dari Persamaan (1.25–1.31) bahwa CNN 1D secara komputasi jauh lebih efisien daripada CNN 2D dalam hal pengoperasian pada data 1D karena berbagai faktor:

- Penelitian terkini mengungkapkan bahwa CNN 1D dengan arsitektur yang relatif dangkal (yaitu, sejumlah kecil lapisan tersembunyi dan neuron) mampu mempelajari tugas-tugas kompleks melalui sinyal 1D seperti klasifikasi sinyal elektrokardiogram (EKG) (Kiranyaz dkk., 2017). Meskipun jaringan dengan arsitektur dangkal relatif lebih mudah diimplementasikan dan dilatih, untuk tugas-tugas dengan tingkat kesulitan yang hampir sama, CNN 2D biasanya memerlukan arsitektur yang lebih dalam.


- Pengaturan perangkat keras khusus diperlukan untuk pelatihan CNN 2D yang mendalam, sementara komputer berdaya rendah pun cukup memadai untuk pelatihan CNN 1D.
- CNN 1D sangat cocok untuk aplikasi waktu nyata (real-time) berkat kebutuhan komputasinya yang rendah. Penggunaan CNN 1D dalam deteksi kerusakan struktural waktu nyata telah terbukti menghasilkan kinerja yang sukses.

1.5 PENGGUNAAN CNN 1D DALAM APLIKASI INFRASTRUKTUR SIPIL

Sebagaimana telah disebutkan sebelumnya, CNN 1D lebih efisien daripada CNN 2D dalam hal pengoperasian data 1D, dan inilah alasan mengapa CNN 1D yang ringkas lebih disukai daripada CNN 2D dalam berbagai aplikasi sains dan teknik. CNN 1D telah digunakan secara luas di berbagai bidang teknik. CNN 1D telah berhasil digunakan dalam pemantauan elektrokardiogram (EKG) waktu nyata; pengenalan suara otomatis, pemantauan kondisi mesin berputar, dan pada konverter multilevel berdaya tinggi. Untuk infrastruktur sipil, CNN terutama digunakan untuk mendeteksi kerusakan dalam aplikasi pemantauan kesehatan struktural.

Kerusakan merupakan indikator penting untuk menilai integritas dan keamanan struktur teknik sipil, serta menjadi fokus utama dalam penelitian pemantauan kesehatan struktural. Respons getaran struktur telah lama digunakan sebagai alat bantu dalam berbagai konteks, seperti pengujian modal, analisis kenyamanan layanan getaran, penilaian kondisi, dan pemantauan infrastruktur sipil. Respons getaran juga berperan penting dalam deteksi kerusakan struktural dengan menggunakan CNN 1D, yang telah menunjukkan kinerja yang sukses. Proses deteksi kerusakan berbasis getaran umumnya mencakup tiga tahap: pendeteksian kerusakan sebagai langkah awal, pelokasian kerusakan sebagai tahap kedua, dan kuantifikasi tingkat kerusakan sebagai langkah terakhir. Dalam literatur, penelitian sering kali berfokus pada satu atau beberapa tahap ini saja.

Penerapan pertama CNN 1D untuk deteksi kerusakan berbasis getaran dilakukan oleh Abdeljaber et al. (2017). Mereka menggunakan struktur rangka baja skala besar dalam eksperimen dengan satu akselerometer per node, total sebanyak 30 node. Struktur ini dapat dianggap sebagai salah satu model stadium berinstrumen terbesar yang pernah dibangun di lingkungan laboratorium. Kerusakan buatan sengaja ditimbulkan dengan memlonggarkan baut pada sambungan balok pengisi. Meskipun perubahan ini tidak signifikan pada kekakuan rotasi sambungan, semua langkah proses deteksi kerusakan struktural diselesaikan dengan menggunakan CNN 1D. Untuk proses deteksi kerusakan, masing-masing CNN 1D dilatih untuk 31 kondisi kerusakan (satu kondisi kerusakan per simpul, dan satu kondisi tidak rusak di mana tidak ada baut yang dilonggarkan) dengan merekam respons getaran melalui eksitasi shaker untuk setiap kondisi. Setiap CNN 1D ditugaskan ke sebuah simpul untuk memproses data lokal melalui akselerometer yang ditempatkan di simpul tersebut.



Gambar 1.13: Mock-up kisi baja struktur stadion laboratorium dengan dimensi tapak 4,2 m×4,2 m.

Sistem ini diuji pada berbagai kondisi kerusakan, baik tunggal maupun ganda, dan berhasil mendeteksi semua kasus tersebut. Berdasarkan analisis kompleksitas komputasi, diperlihatkan bahwa dengan menggunakan komputer standar, kecepatan deteksi kerusakan mencapai 45 kali lebih cepat dari kebutuhan waktu nyata. Temuan ini kemudian dipatenkan.

Setelah pengujian awal menggunakan akselerometer berkabel dengan eksitasi *shaker*, kelompok peneliti yang sama melanjutkan dengan pengujian lebih lanjut menggunakan metodologi CNN 1D yang dimodifikasi. Mereka menerapkan sensor nirkabel pada struktur laboratorium yang sama dan kembali berhasil mencapai hasil deteksi kerusakan yang akurat. Berdasarkan analisis kompleksitas komputasi, penggunaan sensor nirkabel menghasilkan kecepatan pemrosesan 37 kali lebih cepat daripada persyaratan waktu nyata. Dengan arsitektur dua lapis CNN (masing-masing terdiri dari empat neuron), pengujian dengan sensor nirkabel menunjukkan kinerja unggul meskipun pelatihan model dilakukan dalam kondisi getaran lingkungan tanpa bantuan eksitasi *shaker*.

Kelompok peneliti tersebut juga mengaplikasikan CNN 1D pada data *Benchmark* yang telah tersedia. Mereka mengembangkan sistem deteksi kerusakan yang disempurnakan yang memerlukan upaya pelatihan yang lebih sedikit. Sistem yang diperbarui ini kembali terbukti berhasil untuk deteksi dan kuantifikasi kerusakan pada data uji. Dalam sebuah studi terbaru, CNN 1D digunakan untuk mengevaluasi tingkat keparahan kerusakan pada model balok kantilever elemen hingga (*Finite Element/ FE*) dengan tumpuan pegas rotasi non-kaku. Kerusakan disimulasikan dengan mengurangi kekakuan pegas rotasi pada lokasi tumpuan, dan CNN 1D dilaporkan bekerja efisien dalam menilai tingkat keparahan kerusakan tersebut. Selain itu, penelitian lain berhasil memanfaatkan CNN 1D untuk deteksi cacat otonom pada dek jembatan menggunakan radar penembus tanah (*Ground-Penetrating Radar*), yang memperluas aplikasi praktis dari metode ini.



Gambar 1.14: Sensor nirkabel yang digunakan pada struktur grid laboratorium.

1.6 KESIMPULAN

Jaringan Saraf Tiruan Konvolusional (CNN) adalah jenis ANN umpan-maju yang digunakan secara luas dalam berbagai aplikasi pembelajaran mesin (ML) yang melakukan operasi konvolusi dan pengumpulan data secara berurutan dalam arsitektur hierarkis. CNN 1D baru-baru ini mencapai kinerja superior di berbagai bidang teknik dengan efisiensi komputasi yang elegan. Dalam bab ini, penulis menyajikan evolusi ANN menjadi CNN, mendemonstrasikan konsep-konsep utama dan prosedur langkah demi langkah untuk menunjukkan cara kerja CNN 1D. Bab ini dimulai dengan motivasi di balik sistem AI dan dilanjutkan dengan tinjauan umum ANN. Kemudian, MLP dijelaskan; dan pelatihan CNN 2D dan 1D disajikan. Terakhir, aplikasi CNN 1D pada infrastruktur sipil dibahas secara singkat.

Berdasarkan hasil studi kasus deteksi kerusakan struktural yang menggunakan CNN 1D kompak, dilaporkan bahwa CNN 1D dapat secara tepat membedakan data riwayat waktu percepatan yang kompleks dan tidak berkorelasi untuk mendeteksi, menemukan, dan mengkuantifikasi kerusakan struktural pada struktur laboratorium skala besar, dan pada kumpulan data tolok ukur yang ada. Meskipun eksitasi shaker digunakan untuk pengujian sensor berkabel dan kondisi getaran ambien digunakan untuk pengujian sensor nirkabel, hasil analisis kompleksitas komputasi menunjukkan bahwa total waktu yang dibutuhkan untuk klasifikasi sinyal 1 detik adalah 45 kali dan 37 kali lebih cepat daripada persyaratan waktu nyata, masing-masing untuk pengujian sensor berkabel dan nirkabel.

BAB 2

PREDIKSI PERILAKU KESELAMATAN DENGAN AI DAN REGRESI LINIER

2.1 PENDAHULUAN

Dalam beberapa tahun terakhir, sektor konstruksi mencatat tingkat kecelakaan kerja yang tinggi. Sebagai contoh, di Selandia Baru, sektor ini menyumbang porsi terbesar kecelakaan kerja pada tahun 2019, mengakibatkan kerugian ekonomi lebih dari 100 juta USD. Investigasi terhadap akar penyebab kecelakaan telah menjadi fokus penting dalam penelitian keselamatan terkini. Penelitian menunjukkan bahwa banyak kecelakaan kerja sebenarnya dapat diprediksi sebelumnya, karena sering kali merupakan akibat dari perilaku tidak aman secara retrospektif. Oleh karena itu, pemahaman apriori mengenai perilaku keselamatan pekerja dianggap sangat berguna dalam konteks manajemen keselamatan.

Praktik manajemen keselamatan dirancang sebagai intervensi proaktif untuk mencegah terjadinya kecelakaan. Prediksi awal terhadap perilaku pekerja dapat membantu mengidentifikasi individu berisiko yang berpotensi melakukan tindakan tidak aman di masa depan. Wawasan semacam ini memungkinkan perancangan praktik manajemen yang lebih efektif untuk meminimalkan kecelakaan dan mengurangi tingkat cedera. Selain itu, prediksi perilaku juga dapat meningkatkan kesadaran diri pekerja serta pengetahuan mereka tentang respons yang diharapkan dan risiko terkait, sehingga mendorong perilaku kerja yang lebih aman.

Studi terbaru mengungkapkan bahwa dorongan untuk berperilaku aman sangat bervariasi antarindividu, dan banyak dipengaruhi oleh ciri kepribadian. Peran kepribadian dalam perilaku keselamatan didukung oleh sejumlah teori perilaku, seperti teori penentuan nasib sendiri (*self-determination theory*) dan teori perilaku kerja bertujuan (*theory of purposeful work behavior*). Menurut teori-teori ini, perilaku keselamatan merupakan fungsi dari upaya individu untuk mencapai tujuan tertentu di tempat kerja seperti kebersamaan, status, pengendalian diri, atau prestasi.

Sebagai contoh:

- Sifat keramahan (*agreeableness*) dikaitkan dengan tujuan kebersamaan. Individu dengan keramahan tinggi cenderung bekerja lebih aman karena perilaku tidak aman dapat membahayakan rekan dan merusak hubungan interpersonal.
- Sifat ekstrasversi berkaitan dengan pencapaian status. Individu ekstrover mungkin bekerja produktif tetapi terkadang mengabaikan keselamatan untuk mempertahankan keunggulan kompetitif.
- Neurotisme berkaitan dengan pengendalian diri. Individu dengan neurotisme tinggi sering kali memiliki kontrol diri rendah dan emosi negatif, yang dapat mengganggu pemikiran dan memengaruhi perilaku keselamatan.

- Kehati-hatian (conscientiousness) berkaitan dengan pencapaian tujuan. Individu yang hati-hati cenderung berperilaku aman karena tindakan tidak aman dapat membahayakan orang lain atau menghambat penyelesaian pekerjaan.
- Penelitian sebelumnya tentang hubungan antara kepribadian dan perilaku keselamatan banyak mengandalkan metode regresi linier (LR). Namun, temuan meta-analisis mutakhir menunjukkan bahwa hubungan ini sering bersifat nonlinier. Metode LR yang berdasarkan asumsi linear tidak mampu menangkap kompleksitas nonlinier tersebut, sehingga berpotensi menghasilkan pemetaan prediktif yang tidak akurat. Hal ini mempertanyakan kevalidan model LR yang dikembangkan dalam studi-studi terdahulu.

Di sisi lain, jaringan saraf tiruan (NN) telah mendapatkan popularitas yang signifikan di bidang prediksi statistik. Berbeda dengan LR yang berbasis aturan, NN merupakan pendekatan pembelajaran mesin berbasis data yang memungkinkan identifikasi pola alami antar variabel tanpa prasangka apa pun terkait struktur matematika data dan menggunakan algoritma untuk membangun model berdasarkan data guna membuat inferensi tentang kemungkinan hasil di masa mendatang.

NN telah terbukti mencapai tingkat akurasi tinggi dalam penentuan hubungan kompleks di berbagai bidang seperti diagnosis medis, peramalan keuangan, pengenalan suara, dan prediksi perilaku. Mengingat bahwa NN memungkinkan penentuan pola alami antar variabel (yang dapat berupa nonlinier maupun linier), penggunaan NN dapat mengatasi keterbatasan linearitas model LR yang dikembangkan dalam penelitian sebelumnya sebagaimana disebutkan di atas. Untuk berkontribusi pada perkembangan literatur penelitian di bidang ini, bab ini bertujuan untuk menerapkan NN guna mengembangkan penentuan yang lebih andal tentang hubungan prediktif antara ciri kepribadian pekerja konstruksi dan perilaku keselamatan yang diinginkan. Untuk memastikan apakah hubungan tersebut dapat dijelaskan paling baik dengan model linier atau nonlinier, penulis mengembangkan model LR dan membandingkan akurasi prediksi dengan model NN.

Bab ini disusun sebagai berikut. Dataset memperkenalkan data yang dikumpulkan untuk melakukan simulasi numerik NN dan LR. Pengembangan model NN dan LR disajikan dalam Jaringan Syaraf Tiruan dan Model Regresi Linier. Selanjutnya, hasil, yang melibatkan evaluasi dan perbandingan kinerja prediksi model NN dan LR, dibahas dalam Hasil dan Pembahasan. Terakhir, Kesimpulan merangkum hasil, menginterpretasikan implikasi praktis, mencantumkan batasan, dan merekomendasikan arah penelitian di masa mendatang.

2.2 KUMPULAN DATA

Pengumpulan data yang relevan untuk pengembangan model merupakan langkah awal yang krusial dalam penelitian ini. Sebagaimana disebutkan di Bagian Pendahuluan, bab ini bertujuan untuk memastikan hubungan prediktif antara ciri-ciri kepribadian pekerja konstruksi dan perilaku keselamatan yang diinginkan. Dengan menggunakan ukuran kepribadian dan perilaku sebagaimana ditentukan di bawah ini, data dikumpulkan dari 268 pekerja konstruksi yang merupakan kumpulan data untuk penelitian ini.

Pengukuran Kepribadian

Berdasarkan penelitian sebelumnya, tiga instrumen pengukuran kepribadian yang paling banyak diterima dan digunakan dalam penelitian psikologi adalah *Big Five Inventory* (BFI), *NEO Five-Factor Inventory* (NEO-FFI), dan *Revised NEO Personality Inventory* (NEO-PI-R). Sifat psikometrik instrumen-instrumen ini seperti reliabilitas dan validitas telah teruji secara ekstensif dan diakui keandalannya.

Dari perspektif praktis, BFI dianggap lebih efisien dibandingkan NEO-FFI dan NEO-PI-R karena sifatnya yang ringkas. BFI hanya memuat 44 butir pertanyaan dan dapat diselesaikan dalam sekitar 5 menit, sementara NEO-FFI (60 butir) membutuhkan sekitar 10 menit, dan NEO-PI-R (240 butir) memerlukan waktu hingga 45 menit. Instrumen yang terlalu panjang berisiko menimbulkan kelelahan, penolakan partisipasi, atau respons yang tidak cermat—yang dapat mengurangi validitas data. Oleh karena itu, BFI dipilih sebagai instrumen yang lebih sesuai untuk pengukuran kepribadian dalam konteks ini.

Namun, perlu dicatat bahwa BFI seperti juga NEO-FFI dan NEO-PI-R—awalnya dikembangkan sebagai alat ukur kepribadian umum. Item-itemnya tidak secara spesifik merujuk pada konteks tertentu, sehingga dapat dipersepsikan berbeda oleh responden tergantung situasi (misalnya, di tempat kerja vs. di rumah). Untuk mengatasi keterbatasan ini, BFI dapat diadaptasi secara kontekstual.

Schmit et al. (1995) mengembangkan versi kontekstual dari BFI yang khusus dirancang untuk konteks pekerjaan, dengan menambahkan frasa "di tempat kerja" pada setiap item. Adaptasi ini menghasilkan BFI Spesifik Pekerjaan, yang lebih tepat untuk menangkap perilaku kepribadian dalam setting pekerjaan. Perlu diketahui, subskala keterbukaan tidak dimasukkan dalam adaptasi ini karena dua alasan:

1. Penambahan frasa "di tempat kerja" dianggap tidak relevan untuk banyak item dalam subskala keterbukaan.
2. Meta-analisis terbaru menunjukkan tidak adanya korelasi yang signifikan antara sifat keterbukaan dan perilaku keselamatan kerja.

Sifat psikometrik BFI Spesifik Pekerjaan termasuk reliabilitas dan validitasnya—telah diverifikasi melalui berbagai penelitian. Instrumen ini akhirnya digunakan sebagai alat ukur kepribadian dalam studi ini, dengan total 34 item yang mencakup empat dimensi kepribadian: ekstrasversi, keramahan, kehati-hatian, dan neurotisisme.

Pengukuran Perilaku Keselamatan

Dalam literatur, telah disarankan bahwa observasi perilaku dapat mengekspos peneliti ke lingkungan kerja langsung para pekerja, sehingga menimbulkan risiko tertentu mengingat sifat lokasi konstruksi yang berbahaya. Selain itu, observasi perilaku berpotensi mengganggu kelancaran proses konstruksi, sehingga metode ini umumnya tidak disukai di sebagian besar lingkungan kerja. Tinjauan publikasi terkini menunjukkan bahwa pelaporan mandiri merupakan teknik yang baik dan banyak digunakan dalam penelitian perilaku di sektor konstruksi saat ini.

Mempertimbangkan hal-hal tersebut, partisipan dalam penelitian ini diminta untuk melaporkan secara mandiri perilaku keselamatan kerja yang mereka tunjukkan. Skala Perilaku

Keselamatan (*Safety Behavior Scale – SBS*) yang dikembangkan oleh Hayes et al. (1998) dipilih sebagai instrumen penelitian karena memiliki beberapa keunggulan. Pertama, SBS dikembangkan berdasarkan teori-teori perilaku yang relevan dan telah teruji melalui penelitian selama beberapa dekade dengan melibatkan ratusan ribu partisipan, yaitu teori perilaku kerja yang bertujuan dan teori perilaku terencana.

Menurut teori-teori tersebut, pemahaman yang komprehensif tentang perilaku keselamatan kerja yang diinginkan terdiri atas dua dimensi, yaitu: kinerja tugas (*task performance*) dan kinerja kontekstual (*contextual performance*). Kinerja tugas mengacu pada perilaku kepatuhan yang dilakukan individu untuk menjaga keselamatan dirinya sendiri, seperti tidak mengambil jalan pintas, menggunakan alat pelindung diri, serta mengikuti prosedur dan peraturan keselamatan. Sementara itu, kinerja kontekstual merujuk pada aktivitas keselamatan sukarela seperti melaporkan masalah keselamatan, menjaga kebersihan tempat kerja, dan memperhatikan keselamatan rekan kerja. Perilaku ini mungkin tidak secara langsung berkontribusi pada keselamatan individu, tetapi berperan dalam menciptakan lingkungan kerja yang mendukung keselamatan.

SBS dikembangkan secara komprehensif oleh Hayes et al. (1998) untuk mencakup beragam topik perilaku guna mengukur kedua dimensi tersebut, termasuk mengambil jalan pintas, menggunakan peralatan keselamatan, mengikuti prosedur, melaporkan masalah, menjaga kebersihan, dan memperhatikan keselamatan rekan kerja. Dengan demikian, sepengetahuan penulis, penggunaan SBS dapat memberikan penilaian yang lebih memadai terhadap perilaku keselamatan kerja dibandingkan dengan beberapa instrumen yang digunakan dalam penelitian sebelumnya di bidang manajemen konstruksi. Sebagai contoh, Patel dan Jha (2015) menilai perilaku keselamatan hanya dengan satu item, yaitu: 'Saya (sendiri) mengikuti semua prosedur keselamatan untuk pekerjaan yang saya lakukan'. Sementara Guo et al. (2016) menggunakan empat item yang hanya berfokus pada penggunaan peralatan keselamatan, tanpa memasukkan aspek perilaku lain seperti kepatuhan terhadap prosedur.

Kedua, SBS memiliki keunggulan tambahan berupa keringkasan (hanya 11 item) dan reliabilitas yang sangat baik ($\alpha = 0,85$), yang melebihi ambang batas yang diterima secara umum ($\alpha > 0,70$) sebagaimana dikemukakan oleh Wagner III (2016) dan telah dilaporkan dalam artikel pengembangan skala tersebut. Keringkasan ini membuat SBS mudah dan efisien untuk diimplementasikan. Selama bertahun-tahun, SBS telah banyak digunakan dalam penelitian keselamatan kerja, dan reliabilitasnya telah diverifikasi secara konsisten oleh berbagai peneliti berikutnya, seperti yang ditunjukkan dalam studi Gao et al. (2019b) serta Singh dan Misra (2020), yang mengonfirmasi keandalan instrumen ini.

2.3 MODEL JARINGAN SARAF TIRUAN DAN REGRESI LINIER


Pada bagian ini, model NN dan LR dikembangkan untuk mensimulasikan secara numerik hubungan prediktif antara ciri kepribadian pekerja konstruksi dan perilaku keselamatan yang diinginkan.

Model Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) adalah model matematika yang terdiri dari "neuron biologis" buatan dalam beberapa lapisan konduktif yang meniru cara kerja otak manusia, seperti proses pemrosesan dan adaptasi informasi (Gambar 2.1). Neuron pada lapisan masukan, tersembunyi, dan keluaran masing-masing bertanggung jawab untuk menerima sinyal masukan, memproses sinyal yang diterima, dan mendekode sinyal yang telah diproses menjadi keluaran.

Keluaran JST bergantung pada bobot antar neuron di berbagai lapisan dan bias neuron di lapisan tersembunyi dan keluaran (Gambar 2.1). Bobot menunjukkan kekuatan koneksi tertentu antara dua neuron Misalnya, indeks bobot w_{jk}^H pada Gambar 2.1 mengacu pada kekuatan koneksi antara neuron masukan ke- j dan neuron tersembunyi ke- k . Bias dapat dianggap sebagai masukan tambahan untuk setiap neuron, yang merupakan konstanta dan digunakan untuk menyesuaikan jumlah masukan untuk setiap neuron guna meningkatkan kemampuan komputasi Jaringan Saraf Tiruan. Misalnya, indeks bias H pada Gambar 2.1 mengacu pada bias neuron tersembunyi ke- k . Selama proses pembelajaran yang menerapkan algoritma LM-BP, Jaringan Saraf Tiruan secara iteratif menyesuaikan nilai bobot dan bias untuk meminimalkan kesalahan antara keluaran yang diprediksi dan keluaran.

Pengembangan Jaringan Saraf Tiruan melibatkan penentuan jumlah lapisan tersembunyi, pemilihan kombinasi fungsi aktivasi, penentuan jumlah neuron pada lapisan masukan, tersembunyi, dan keluaran, penentuan rasio pemisahan data, dan pelatihan Jaringan Saraf Tiruan. Setiap langkah dijelaskan lebih rinci di bawah ini.



I_j : the j^{th} input neuron H_k : the k^{th} hidden neuron O_i : the i^{th} output neuron
 W_{jk}^H : weight between the j^{th} input neuron and k^{th} hidden neuron
 W_{ki}^O : weight between the k^{th} hidden neuron and i^{th} output neuron
 $bias_k^H$: bias of the k^{th} hidden neuron $bias_i^O$: bias of the i^{th} output neuron

Gambar 2.1: Arsitektur contoh jaringan saraf tiruan.

Jumlah Lapisan Tersembunyi

Secara umum, Jaringan Saraf Tiruan (JST) hanya memiliki satu lapisan masukan dan satu lapisan keluaran, dan dapat terdapat satu atau lebih lapisan tersembunyi di antaranya. Banyak peneliti telah menunjukkan bahwa satu lapisan tersembunyi saja sudah cukup bagi JST untuk mengaproksimasi pemetaan nonlinier kompleks apa pun dengan akurasi yang diinginkan. Berdasarkan pertimbangan di atas, JST tiga lapis (yaitu, satu lapisan masukan, satu lapisan tersembunyi, dan satu lapisan keluaran) digunakan dalam penelitian ini.

Kombinasi Fungsi Aktivasi

Langkah selanjutnya adalah memilih kombinasi fungsi aktivasi. Dalam Jaringan Saraf Tiruan (NN), fungsi aktivasi berjalan pada neuron di lapisan tersembunyi dan lapisan keluaran, mengubah sinyal masukan neuron menjadi sinyal keluaran. Fungsi aktivasi yang umum digunakan adalah tansig, logsig, dan purelin. Tansig dan logsig merupakan fungsi nonlinier, sedangkan purelin merupakan fungsi linier. Fungsi nonlinier (tansig dan logsig) mampu menjalankan aturan komputasi yang lebih kompleks daripada fungsi linier (purelin).

Lapisan tersembunyi Jaringan Saraf Tiruan melakukan komputasi pada masukan jaringan dan mentransfer hasil komputasi ke lapisan keluaran, sementara fungsi nonlinier (tansig dan logsig) umumnya digunakan di lapisan tersembunyi untuk meningkatkan kapabilitas komputasi Jaringan Saraf Tiruan. Khususnya, di antara fungsi-fungsi nonlinier, tansig terbukti berkinerja lebih baik daripada logsig dalam mencapai akurasi prediksi yang lebih tinggi dengan memori kerja dan waktu pelatihan yang lebih sedikit. Mempertimbangkan pembahasan di atas, fungsi nonlinier tansig digunakan pada lapisan tersembunyi.

Selain itu, lapisan keluaran Jaringan Saraf Tiruan (NN) mendekode hasil komputasi yang diperoleh pada lapisan tersembunyi untuk menghasilkan keluaran akhir, dan fungsi aktivasi yang digunakan pada lapisan keluaran dapat menentukan rentang keluaran Jaringan Saraf Tiruan (NN). Rentang keluaran berbeda di antara fungsi aktivasi, di mana keluaran fungsi linier (purelin) dapat mengambil nilai apa pun di sepanjang kontinum dari negatif tak terhingga hingga positif tak terhingga dan keluaran fungsi nonlinier (tansig dan logsig) terbatas pada rentang -1 hingga 1 dan 0 hingga 1, masing-masing.

Dalam studi ini, partisipan diminta untuk melaporkan sendiri perilaku keselamatan mereka menggunakan skala Likert 5 poin (1 = sangat tidak setuju, 2 = tidak setuju, 3 = netral, 4 = setuju, 5 = sangat setuju) (Lampiran A2.3). Skor perilaku keselamatan keseluruhan mereka sebagai keluaran NN dihitung dengan menjumlahkan skor pada semua item (Lampiran A2.3) dan kemudian merata-ratakannya sehingga dapat berupa nilai apa pun dalam rentang 1 hingga 5. Dengan mempertimbangkan pembahasan di atas, fungsi linear purelin digunakan pada lapisan keluaran untuk memperluas rentang keluaran NN.

Jumlah Neuron pada Lapisan Masukan, Tersembunyi, dan Keluaran

Selain menentukan jumlah lapisan tersembunyi dan memilih kombinasi fungsi aktivasi, tugas penting lainnya adalah menentukan jumlah neuron pada lapisan masukan, tersembunyi, dan keluaran. Dalam makalah ini, jaringan memiliki empat neuron masukan (satu untuk setiap ciri kepribadian) dan dua neuron keluaran (satu untuk setiap indikator perilaku keselamatan). Untuk menentukan jumlah neuron tersembunyi, digunakan metode yang banyak

direkomendasikan dan digunakan dalam literatur: $m \leq n \leq 2m$ dengan n adalah jumlah neuron tersembunyi dan m adalah jumlah neuron masukan.

Sebagaimana dicatat dalam Patel dan Jha (2015), proses penentuan jumlah neuron tersembunyi juga merupakan proses identifikasi jaringan dengan kinerja terbaik. Oleh karena itu, beberapa uji coba pelatihan dilakukan di MATLAB®, dengan memvariasikan jumlah neuron tersembunyi dari empat hingga delapan ($m \leq n \leq 2m$), untuk mengidentifikasi jaringan berkinerja terbaik dengan memeriksa dua parameter statistik (yaitu, galat kuadrat rata-rata (MSE) dan koefisien determinasi (R^2)), sebagaimana disarankan oleh banyak peneliti.

Mean Squared Error (MSE) dan Koefisien Determinasi (R^2) merupakan ukuran kinerja jaringan yang paling umum karena keduanya menunjukkan kesesuaian global (Rafiei dan Adeli, 2018). Untuk MSE, nilai yang lebih rendah menunjukkan kesesuaian yang lebih baik; untuk R^2 , nilai yang lebih tinggi menunjukkan kesesuaian yang lebih baik (Rafiei dan Adeli, 2018). Kumpulan data yang digunakan dalam prosedur pelatihan dan pengujian dijelaskan di Bagian berikut, Rasio Pemisahan Kumpulan Data.

Rasio Pemisahan Dataset

Untuk memungkinkan evaluasi kinerja jaringan, seluruh dataset biasanya dibagi menjadi tiga kelompok: dataset pelatihan, dataset validasi, dan dataset pengujian (Ramkumar dkk., 2019). Dataset pelatihan digunakan untuk menyesuaikan parameter jaringan (yaitu, bobot dan bias) agar dapat memetakan hubungan input-output dengan lebih baik (Klaassen dkk., 2016). Dataset validasi digunakan untuk menjamin bahwa jaringan tidak mengalami overfitting selama pelatihan.

Overfitting mengacu pada fenomena di mana sistem pembelajaran beradaptasi secara berlebihan terhadap dataset pelatihan dan bahkan terhadap derau dalam data, yang memengaruhi akurasi prediksi model yang telah dilatih untuk input baru. Sebagaimana dicatat dalam Ramkumar dkk. (2019), jaringan dapat melakukan overfitting terhadap dataset pelatihan ketika nilai MSE untuk dataset validasi mulai meningkat, dan pelatihan akan dihentikan pada titik ini untuk mencegah overfitting pada jaringan. Terakhir, dataset pengujian dibuat untuk mengevaluasi kinerja jaringan setelah pengembangannya.

Untuk menentukan rasio pemisahan dataset, telah direkomendasikan dalam literatur bahwa:

1. Dataset pelatihan tidak boleh kurang dari dua pertiga dari keseluruhan dataset; dan
2. Dataset validasi dan pengujian harus seperempat hingga seperdelapan dari dataset pelatihan.

Oleh karena itu, rasio pemisahan data yang umum digunakan untuk dataset pelatihan, validasi, dan pengujian adalah 70:15:15 dan 80:10:10. Selain itu, rasio 70:15:15 direkomendasikan sebagai rasio yang lebih seimbang daripada 80:10:10 untuk mempertahankan sebanyak mungkin porsi data untuk pelatihan dan juga mencakup titik data yang cukup untuk validasi dan pengujian. Oleh karena itu, dalam studi ini, rasio 70:15:15 dipilih, di mana 188 (70 persen), 40 (15 persen), dan 40 (15 persen) sampel dialokasikan secara acak untuk pelatihan, validasi, dan pengujian jaringan yang diusulkan.

Pelatihan Jaringan Saraf Tiruan

Sebagaimana disebutkan dalam Bagian Jumlah Neuron pada Lapisan Masukan, Tersembunyi, dan Keluaran, pelatihan jaringan yang diusulkan dilakukan berulang kali dengan jumlah neuron yang berbeda pada lapisan tersembunyi. Untuk menentukan jaringan dengan kinerja terbaik, dua parameter statistik, MSE dan R^2 , diestimasi dan dibandingkan untuk dataset pelatihan dan validasi. Hasilnya disajikan pada Tabel 2.1. Penulis menemukan bahwa lapisan tersembunyi dengan delapan neuron memberikan kinerja terbaik di antara semua alternatif, menunjukkan nilai MSE terendah dan R^2 tertinggi. Hasilnya, konfigurasi 4-8-2 (4 neuron masukan-8 neuron tersembunyi-2 neuron keluaran) dianggap sebagai konfigurasi dengan kinerja terbaik dan ditentukan untuk jaringan yang diusulkan.

Saat melatih jaringan, bobot antar neuron di berbagai lapisan dan bias neuron tersembunyi serta keluaran disesuaikan untuk memetakan hubungan masukan-keluaran dengan lebih baik. Bobot dan bias konfigurasi berkinerja terbaik (4-8-2) disajikan pada Tabel 2.2.

Tabel 2.1: Parameter statistik model jaringan saraf tiruan.

Jumlah Neuron Tersembunyi	Data set	Parameter Statistik	
		MSE	R^2
4	Training	0,203	0,771
	Validating	0,257	0,651
5	Training	0,234	0,724
	Validating	0,192	0,753
6	Training	0,176	0,811
	Validating	0,163	0,823
7	Training	0,099	0,882
	Validating	0,103	0,873
8	Training	0,041	0,942
	Validating	0,058	0,931

Arsitektur Jaringan Saraf Tiruan yang Dikembangkan

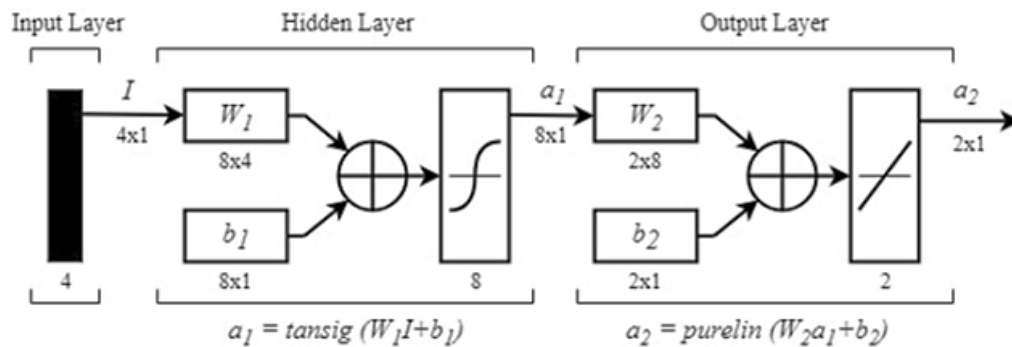
Gambaran umum arsitektur jaringan yang dikembangkan disajikan pada Gambar 2.2. Masukan I adalah matriks 4×1 , yang merepresentasikan unit empat sifat kepribadian, yaitu ekstroversi, keramahan, kehati-hatian, dan neurotisme. Ukuran matriks bobot pertama W_1 adalah 8×4 , yang menghubungkan 4 neuron masukan dengan 8 neuron tersembunyi. Matriks bobot kedua W_2 adalah matriks 2×8 , yang menunjukkan koneksi antara 8 neuron tersembunyi dan 2 neuron keluaran. Matriks bias b_1 (8×1) dan b_2 (2×1) pada Gambar 2.2 menunjukkan bias dari 8 neuron tersembunyi dan 2 neuron keluaran.

Seperti ditunjukkan pada Gambar 2.2, jaringan yang dikembangkan memiliki lapisan tersembunyi dan lapisan keluaran yang masing-masing dibangun berdasarkan fungsi nonlinier tansig dan fungsi linier purelin. Matriks a_1 adalah keluaran dari lapisan tersembunyi, di mana matriks masukan I dikalikan terlebih dahulu dengan bobot W_1 , kemudian hasil perkaliannya

dijumlahkan dengan bias b_1 dan diteruskan ke fungsi tansig. Matriks a_2 (2x1) adalah keluaran dari jaringan, yang merepresentasikan satuan dari dua dimensi perilaku keselamatan, yaitu kinerja tugas dan kinerja kontekstual. Untuk mendapatkan matriks a_2 , matriks a_1 dikalikan dengan bobot W_2 , kemudian hasil perkaliannya dijumlahkan dengan bias b_2 dan diteruskan ke fungsi purelin.

Tabel 2.2: Bobot dan bias.

Neuron Input/Output (I_j, O_i)	Bobot / Bias	Neuron Tersembunyi (H_k)							
		H_1	H_2	H_3	H_4	H_5	H_6	H_7	H_8
I_1	$w_{1,k}^{IH}$	0.128	0.219	-0.452	0.325	2.325	1.831	1.017	-4.231
I_2	$w_{2,k}^{IH}$	-1.232	3.588	-1.433	5.222	2.176	-2.362	3.255	2.465
I_3	$w_{3,k}^{IH}$	3.247	-1.357	3.682	-2.425	-3.683	-6.433	-2.675	2.791
I_4	$w_{4,k}^{IH}$	1.342	-1.243	3.369	-1.435	-2.355	-2.131	2.323	1.266
	$bias_k^H$	-2.612	-0.322	1.991	-2.345	1.378	2.879	4.356	-2.338
O_1	$w_{k,1}^{HO}$	-2.364	3.256	0.111	-3.254	1.467	2.645	2.122	3.211
O_2	$w_{k,2}^{HO}$	-2.213	-1.121	-3.122	-3.122	3.322	2.322	-1.113	5.382
	$bias_i^O$	0.234 (untuk O_1)				0.164 (untuk O_2)			



Gambar 2.2: Arsitektur jaringan yang dikembangkan.

Akibatnya, matriks keluaran a_2 dapat dihitung menggunakan rumus berikut:

$$w_1 I + b_1 = \begin{pmatrix} \sum_{j=1}^{N_j} w_{j,1}^{IH} I_j + bias_1^H \\ \vdots \\ \sum_{j=1}^{N_j} w_{j,k}^{IH} I_j + bias_k^H \\ \vdots \\ \sum_{j=1}^{N_j} w_{j,8}^{IH} I_j + bias_8^H \end{pmatrix} \quad (2.1)$$

$$a_1 = \text{tansig}(W_1 I + b_1) = \frac{2}{1 + e^{-2(W_1 I + b_1)}} - 1 \quad (2.2)$$

$$W_2 a_1 + b_2 = \begin{pmatrix} w_{1,1}^{HO} & \dots & w_{k,1}^{HO} & \dots & w_{8,1}^{HO} \\ w_{1,2}^{HO} & \dots & w_{k,2}^{HO} & \dots & w_{8,2}^{HO} \end{pmatrix} \times a_1 + \begin{pmatrix} bias_1^O \\ bias_2^O \end{pmatrix} \quad (2.3)$$

$$a_2 = \text{purelin}(W_2 a_1 + b_2) = W_2 a_1 + b_2 \quad (2.4)$$

di mana I = matriks masukan; W_1 = matriks bobot (termasuk bobot antara neuron masukan dan tersembunyi); W_2 = matriks bobot (termasuk bobot antara neuron tersembunyi dan keluaran); b_1 = matriks bias (termasuk bias neuron tersembunyi); b_2 = matriks bias (termasuk bias neuron keluaran); a_1 = keluaran lapisan tersembunyi; a_2 = keluaran jaringan; N_j = jumlah total neuron masukan ($N_j = 4$); definisi dan nilai $w_{j,k}^{IH}$ (misalnya, $w_{j,1}^{IH}$, $w_{j,8}^{IH}$), $w_{k,i}^{HO}$ (misalnya, $w_{k,1}^{HO}$, $w_{k,2}^{HO}$), $bias_k^H$ (misalnya, $bias_1^H$, $bias_8^H$), dan $bias_i^O$ (misalnya, $bias_1^O$, $bias_2^O$) dapat ditemukan di Tabel 2.2.

Model Regresi Linier

LR adalah metode statistik yang digunakan untuk memodelkan hubungan antara variabel keluaran dan satu atau lebih variabel masukan dengan cara menyesuaikan semua titik data ke dalam bentuk linier (Jorgensen, 2019): $y = b_1 x_1 + b_2 x_2 + \dots + b_i x_i + c$ dengan y adalah variabel keluaran, x_i adalah variabel masukan ke- i , b_i adalah bobot variabel masukan ke- i , dan c adalah konstanta yang digunakan untuk menyesuaikan jumlah variabel masukan terbobot agar mendekati variabel keluaran dengan sebaik-baiknya.

Dengan menggunakan dataset yang mencakup 188 sampel pelatihan dan 40 sampel validasi sebagaimana dijelaskan di Bagian Rasio Pembagian Data, perhitungan LR dilakukan menggunakan program komputer SPSS (Schoukens dkk., 2016), dan rumus LR berikut diperoleh untuk memprediksi perilaku keselamatan yang diinginkan pekerja konstruksi:

$$y_1 = -0.086x_1 + 0.554x_2 + 0.543x_3 - 0.166x_4 + 0.658 \quad (2.5)$$

$$y_2 = -0.132x_1 + 0.755x_2 + 0.343x_3 - 0.170x_4 + 1.011 \quad (2.6)$$

di mana y_1 = kinerja tugas; y_2 = kinerja kontekstual; x_1 = Ekstroversi; x_2 = Keramahan; x_3 = Kehati-hatian; dan x_4 = Neurotisme.

Selain itu, telah ditunjukkan bahwa LR umumnya memiliki struktur matematika yang relatif sederhana dibandingkan dengan teknik nonlinier seperti NN (Velasco dkk., 2020). Struktur sederhana seperti itu dapat menyebabkan ketidakstabilan persamaan regresi, karena sensitif terhadap potensi pemutusan struktural pada sinyal masukan (Peters dkk., 2019). Pemutus struktural mengacu pada pergeseran mendadak pada kemiringan garis tren pada serangkaian titik data. Untuk memastikan stabilitas struktural rumus LR (2.5) dan (2.6),

pendekatan yang banyak digunakan uji Chow diadopsi. Uji Chow dapat memperkirakan apakah parameter model LR stabil secara struktural, dan dijalankan sebagai berikut:

1. Mengidentifikasi patahan struktural dalam dataset yang digunakan untuk mengembangkan model dan membagi dataset menjadi subset pada titik patahan tersebut;
2. Melakukan regresi terpisah pada seluruh dataset dan setiap subset data;
3. Mengambil jumlah kuadrat residual untuk setiap regresi; dan
4. Menghitung statistik Chow menggunakan rumus:

$$F = \frac{(N - 2k)[R_w - (\sum_{j=1}^n R_j)]}{k(\sum_{j=1}^n R_j)} \quad (2.7)$$

di mana F = statistik Chow; R_w = jumlah kuadrat residual regresi untuk seluruh dataset; n = jumlah subdataset yang dibagi berdasarkan pemisahan struktural; j = subdataset ke- j ; R_j = jumlah kuadrat residual regresi untuk subdataset ke- j ; N = jumlah sampel dalam seluruh dataset ($N = 228$, termasuk 188 sampel pelatihan dan 40 sampel validasi sebagaimana ditetapkan di Bagian Rasio Pembagian Data); dan k = jumlah variabel input ($k = 4$, termasuk empat ciri kepribadian).

Uji Chow dilakukan menggunakan program komputer SAS (Song dkk., 2019). Hasil penelitian menunjukkan bahwa terdapat satu patahan struktural pada keseluruhan dataset, yang menghasilkan dua sub-dataset terpisah dan nilai R_w , R_1 dan R_2 untuk rumus LR (2.5) dan (2.6) berturut-turut sebagai berikut: 33,497, 18,143, dan 15,136 ($p < 0,001$); 82,325, 39,693, dan 41,667 ($p < 0,001$). Dengan menerapkan rumus (2.7) di atas, nilai F dihitung masing-masing untuk rumus LR (5) dan (6) sebagai berikut: 0,37 ($p < 0,001$) dan 0,65 ($p < 0,001$). Berdasarkan kriteria uji Chow (Song dkk., 2019), parameter model LR dianggap stabil secara struktural ketika nilai F terhitung lebih kecil dari nilai F -kritis dengan derajat kebebasan ($k, N - 2k$) yang dapat diperoleh dari tabel distribusi F

Sebagaimana telah ditentukan sebelumnya, nilai k dan N masing-masing sama dengan 4 dan 228. Derajat kebebasan untuk nilai F -kritis ditentukan sebagai (4, 220). Berdasarkan tabel distribusi F , nilai F -kritis dengan derajat kebebasan (4, 220) dan nilai p kurang dari 0,001 adalah 4,81. Nilai F terhitung, 0,37 ($p < 0,001$) dan 0,65 ($p < 0,001$), jauh di bawah nilai F –kritis 4,81 ($p < 0,001$), yang menunjukkan bahwa parameter rumus LR (2,5) dan (2,6) stabil secara struktural.

2.4 PREDIKSI KESELAMATAN

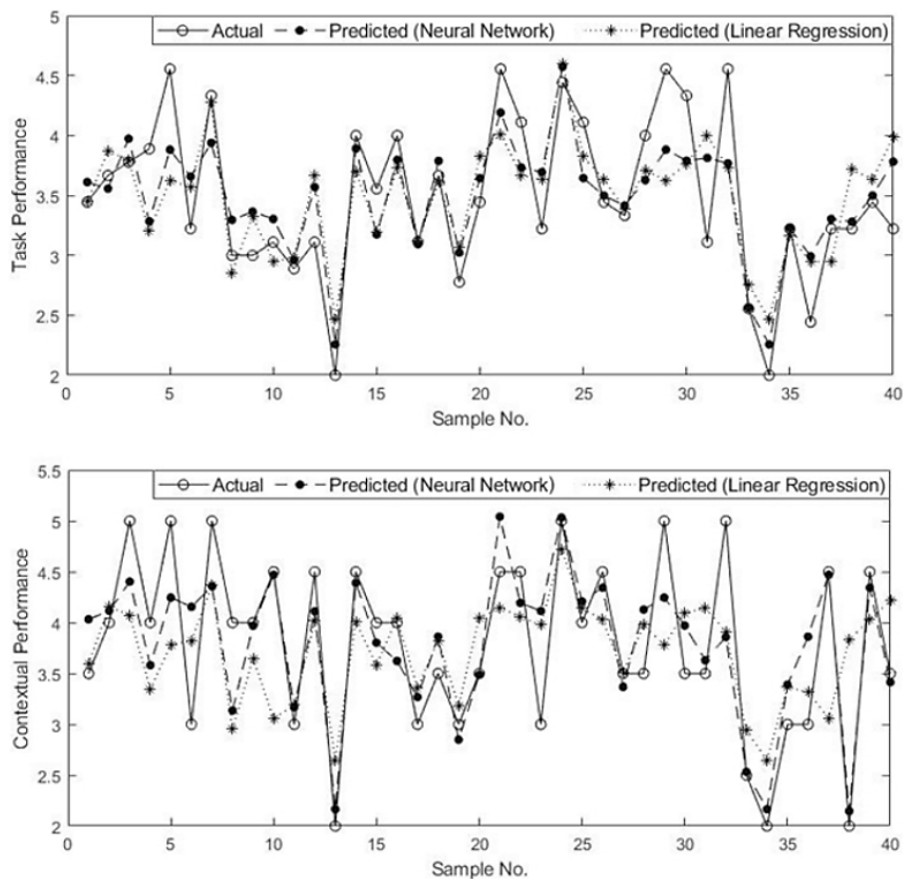
Setelah menentukan arsitektur model NN dan LR, akurasi prediksi dievaluasi pada dataset pengujian. Hasilnya disajikan pada Gambar 2.3, yang menunjukkan perbandingan antara hasil prediksi (NN dan LR) dan hasil aktual pada kinerja tugas dan kinerja kontekstual untuk semua sampel pengujian. Sumbu horizontal plot menguraikan 40 sampel dalam dataset pengujian, dan sumbu vertikal mewakili skor seseorang pada kinerja tugas dan kinerja

kontekstual, di mana skor yang lebih tinggi menunjukkan kinerja yang lebih baik dari seseorang dalam hal niat untuk berperilaku aman di tempat kerja.

Berdasarkan plot prediksi-aktual, akurasi prediksi dievaluasi menggunakan parameter statistik kesalahan generalisasi (E_{gen}), yang merupakan ukuran seberapa akurat suatu model matematika dapat membuat prediksi untuk data yang sebelumnya tidak terlihat (De Jong dkk., 2019). E_{gen} dapat dihitung menggunakan rumus di bawah ini, di mana nilai kurang dari 0,25 dianggap sebagai tingkat kesalahan yang rendah sekaligus tingkat akurasi prediksi yang memuaskan:

$$E_{gen} = \frac{1}{n} \sum_{m=1}^n (Y_m - \hat{Y}_m)^2 \tag{2.8}$$

di mana E_{gen} = galat generalisasi; n = jumlah sampel dalam set data pengujian; Y = hasil aktual untuk sampel ke- m ; \hat{Y} = hasil prediksi untuk sampel ke- m .



Gambar 2.3: Plot prediksi-aktual (kinerja tugas dan kinerja kontekstual).

Dalam studi ini, rasio E_{gen} adalah 0,05 dan 0,09 untuk prediksi NN pada kinerja tugas dan kinerja kontekstual, berturut-turut. Menurut ambang batas (di bawah 0,25), akurasi prediksi model NN yang dikembangkan sangat memuaskan. Selain itu, rasio E_{gen} adalah 0,32 dan 0,41 untuk prediksi LR pada kinerja tugas dan kinerja kontekstual, berturut-turut. Mengingat

ambang batas (di bawah 0,25), akurasi prediksi rumus LR yang dikembangkan tidak memuaskan untuk kinerja tugas dan kontekstual. Dalam perbandingan kinerja NN dan LR seperti yang disajikan di atas, ditemukan bahwa hubungan prediktif antara kepribadian pekerja konstruksi dan perilaku keselamatan yang diinginkan dapat dijelaskan lebih baik dengan NN. Ini menyiratkan bahwa LR tidak dapat berhasil menangkap hubungan kepribadian-perilaku keselamatan dan dengan demikian ada efek nonlinier.

2.5 KESIMPULAN

Bab ini menyajikan pemanfaatan dua model matematika jaringan saraf tiruan (JST) dan regresi linier (LR) untuk memastikan apakah hubungan prediktif antara ciri kepribadian pekerja konstruksi dan perilaku keselamatan yang diinginkan dapat dijelaskan paling baik dengan model linier atau nonlinier. Model JST dan LR yang dikembangkan dapat direpresentasikan oleh ekspresi matematikanya (1) (2) (3) (4) dan (5) (6) sebagaimana ditunjukkan masing-masing dalam Arsitektur Jaringan Saraf Tiruan yang Dikembangkan dan Model Regresi Linier.

Berdasarkan hasil yang diperoleh pada set data pengujian (lihat Bagian Hasil dan Pembahasan), model JST terbukti memprediksi dengan sangat memuaskan dan menghasilkan tingkat kesalahan prediksi yang minimal. Hasil tersebut juga menunjukkan bahwa metode LR menunjukkan kesalahan prediksi yang lebih besar daripada NN, yang mengakibatkan akurasi prediksi yang kurang memuaskan (lihat Hasil dan Pembahasan). Hal ini menyiratkan bahwa LR tidak berhasil menangkap hubungan prediktif antara ciri kepribadian pekerja konstruksi dan perilaku keselamatan yang diinginkan, sehingga terdapat efek nonlinier. Karena semua penelitian sebelumnya di bidang ini menggunakan metode LR untuk mengkaji hubungan kepribadian-perilaku keselamatan (lihat Pendahuluan), bukti empiris (yaitu, efek nonlinier) yang diidentifikasi dalam bab ini memungkinkan penulis untuk meragukan validitas model LR yang dikembangkan dalam penelitian sebelumnya dan mendukung kegunaan model NN yang dikembangkan.

Temuan bab ini menyiratkan implikasi praktis bagi manajemen keselamatan di lokasi kerja. Prediksi awal mengenai perilaku keselamatan yang diinginkan karyawan dapat membantu mengidentifikasi pekerja berisiko yang rentan melakukan perilaku tidak aman. Model NN yang dikembangkan terbukti memiliki akurasi prediksi yang sangat memuaskan dan oleh karena itu direkomendasikan sebagai alat proyeksi potensial untuk membantu para pengambil keputusan proyek menilai seberapa rentan pekerja melakukan perilaku tidak aman di tempat kerja. Manajer lokasi dapat memasukkan data mengenai ciri-ciri kepribadian pekerja dan model NN akan memperkirakan dan mengeluarkan hasil mengenai perilaku keselamatan untuk dipertimbangkan. Model NN dikembangkan untuk membuat prediksi mengenai dimensi-dimensi yang membentuk perilaku keselamatan yang diinginkan individu, yang mencakup kinerja tugas dan kinerja kontekstual. Hal ini bermanfaat tidak hanya dalam mengidentifikasi aspek-aspek yang tidak diinginkan pada individu yang berbeda, tetapi juga dalam merancang praktik manajemen sebelum terjadinya kecelakaan.

Misalnya, individu yang diprediksi memiliki kinerja tugas rendah lebih cenderung melakukan perilaku kerja yang tidak sesuai di masa mendatang, seperti mengambil jalan pintas

dan melanggar aturan keselamatan. Dengan demikian, manajer lokasi dapat mengadopsi intervensi untuk meningkatkan rasa disiplin dan kepatuhan mereka. Mereka yang diprediksi memiliki kinerja kontekstual rendah cenderung enggan melakukan aktivitas keselamatan sukarela di masa mendatang, seperti menjaga kebersihan tempat kerja dan memperhatikan keselamatan rekan kerja. Oleh karena itu, manajer lokasi dapat menggunakan metode insentif untuk mendorong keinginan mereka berkontribusi pada keselamatan organisasi.

Karena keterbatasan finansial dan sumber daya, pengumpulan data terutama difokuskan pada proyek konstruksi di Selandia Baru dengan beberapa sampel diperoleh dari luar negeri. Hal ini mungkin mengabaikan sebagian populasi (yaitu, tenaga kerja konstruksi) yang mungkin penting bagi studi ini. Misalnya, perbedaan budaya berdasarkan wilayah dapat memengaruhi pembentukan ciri kepribadian orang di berbagai negara dan mengakibatkan keragaman berdasarkan wilayah dalam perilaku keselamatan yang diinginkan orang di tempat kerja. Oleh karena itu, akan menarik bagi penelitian mendatang untuk menyelidiki perbedaan regional dalam ciri-ciri kepribadian pekerja konstruksi dan perilaku keselamatan yang diinginkan.

BAB 3

PEMBELAJARAN MESIN UNTUK PREDIKSI BALOK FRP

3.1 PENDAHULUAN

Korosi batang baja merupakan masalah utama dalam struktur beton bertulang (RC). Batang polimer yang diperkuat serat (FRP) memberikan substitusi yang menjanjikan untuk batang baja pada struktur RC, terutama di lingkungan yang keras, karena ketahanannya yang tinggi terhadap korosi, rasio kekuatan-berat yang tinggi, dan ketahanan lelah yang sangat baik. Dalam praktiknya, FRP dapat dibuat dengan berbagai jenis serat termasuk polimer yang diperkuat serat kaca (GFRP), polimer yang diperkuat serat karbon (CFRP), dan polimer yang diperkuat serat aramid (AFRP).

Batang FRP tidak dapat langsung menggantikan batang tulangan baja karena karakteristik mekanisnya yang berbeda. Sebagian besar batang FRP memiliki modulus elastisitas yang relatif rendah dibandingkan baja, dengan hubungan tegangan-regangan linear hingga terjadi kegagalan. Dengan demikian, perilaku lentur dan geser komponen beton bertulang yang diperkuat secara internal dengan FRP (yaitu, komponen FRP-RC) telah diselidiki secara ekstensif, dan berbagai pedoman dikembangkan untuk membantu para insinyur dalam merancang komponen FRP-RC dalam lentur dan geser.

Meskipun sejumlah penyelidikan dilakukan untuk mempelajari perilaku balok FRP-RC, kode desain dan pedoman balok bertulang FRP yang dikembangkan menunjukkan berbagai inkonsistensi. Misalnya, ada pedoman yang memungkinkan desain balok FRP-RC sebagai komponen yang dikontrol tarik atau dikontrol tekan, sementara ketentuan lain hanya memungkinkan balok FRP-RC dirancang sebagai komponen yang dikontrol tekan. Selain itu, faktor reduksi kekuatan yang diadopsi dalam berbagai pedoman desain berbeda secara signifikan. Hal ini menunjukkan perlunya mengkarakterisasi perilaku balok FRP secara menyeluruh sehingga kesepakatan tentang proses desain dapat dicapai.

Baru-baru ini, telah terjadi pergeseran paradigma menuju pemanfaatan teknik berbasis pembelajaran mesin dalam berbagai aspek rekayasa. Khususnya, pembelajaran mesin (ML) telah diterapkan dalam aplikasi rekayasa struktur, termasuk rekayasa gempa bumi, pemantauan kesehatan struktur, prediksi mode kegagalan, kapasitas, dan sifat mekanis material struktur. ML dapat memecah relasi matematika yang kompleks menjadi operasi sederhana dan mengenali pola melalui pembelajaran dari data masukan (pelatihan). Khususnya, jaringan saraf tiruan (JST), mesin vektor pendukung (SVM), dan pemrograman ekspresi gen (GEP) merupakan beberapa algoritma ML yang paling banyak digunakan dalam aplikasi rekayasa struktur. Konsep JST mensimulasikan sistem saraf pusat manusia, di mana semua data masukan dan keluaran terhubung sepenuhnya dengan neuron yang mengirimkan sinyal (informasi) satu sama lain.

Setiap neuron memiliki bobot (faktor) yang dikalibrasi melalui algoritma untuk meminimalkan kesalahan antara data masukan dan keluaran. Sementara itu, GEP meniru

seleksi alam Darwinian dalam evolusi ekspresi prediksi, di mana operasi matematika yang memberikan korelasi lebih tinggi terhadap data keluaran (kesalahan lebih kecil antara data masukan dan keluaran) akan terjadi dibandingkan dengan operasi dengan korelasi lebih rendah. Demikian pula, algoritma SVM digunakan dalam masalah prediksi dan klasifikasi seperti mengidentifikasi mode kegagalan. Algoritma ini mengembangkan hiperbidang pemisah antara dua kelas sebagaimana akan dibahas di bagian selanjutnya.

Beberapa penelitian telah menggunakan ML dalam konteks struktur. Misalnya, pemrograman ekspresi gen (GEP) digunakan dengan basis data eksperimen komprehensif yang terdiri dari ratusan balok beton bertulang serat baja (SFRC) untuk mengembangkan model prediksi kapasitas geser balok. Variabel independen yang digunakan dalam pengembangan model meliputi faktor serat, rasio tulangan longitudinal, kuat tekan silinder beton, dan rasio bentang terhadap kedalaman geser. Model yang diusulkan memberikan akurasi yang lebih unggul dibandingkan model yang sudah ada yang dikembangkan menggunakan regresi linier dan nonlinier, sehingga menghasilkan indeks keandalan yang lebih tinggi (probabilitas kegagalan yang lebih rendah).

ML juga dimanfaatkan untuk menyediakan klasifikasi berbasis risiko bagi bahaya kebakaran jembatan. Tiga algoritma klasifikasi, yaitu Random Forest (RF), Support Vector Machine (SVM), dan Generalized Additive Model (GAM), dilatih dengan basis data yang terdiri dari puluhan jembatan baja dan beton untuk menyediakan klasifikasi berbasis risiko kebakaran. Studi ini juga mengevaluasi signifikansi fitur-fitur yang memengaruhi risiko kebakaran, termasuk bahan bakar, bentang, usia, signifikansi geografis, jenis material, sistem struktur, dan posisi kebakaran.

Lebih lanjut, sebuah kerangka kerja ML dikembangkan untuk memprediksi mode kegagalan dan kapasitas balok beton kinerja ultra-tinggi. Kerangka kerja ini dimulai dengan basis data komprehensif ratusan balok uji, kemudian dilakukan seleksi fitur, dan data dianalisis menggunakan algoritma SVM, ANN, dan k-nearest neighbor untuk mengidentifikasi model kegagalan balok. Selanjutnya, GEP digunakan untuk mengembangkan model prediksi kapasitas yang disederhanakan untuk setiap mode kegagalan. Kerangka kerja ini menunjukkan akurasi tinggi dalam memprediksi mode kegagalan maupun kapasitas.

Penelitian lain menggunakan algoritma SVM untuk regresi dalam memprediksi kapasitas pelat beton bertulang FRP, serta untuk memprediksi modulus elastisitas beton mutu tinggi dan normal. Metodologi desain balok beton bertulang FRP yang disederhanakan dan tangguh sangat penting untuk mengoptimalkan penggunaan batang FRP pada komponen lentur beton bertulang. Untuk mengembangkan metodologi tersebut, kerangka kerja ML digunakan untuk mengidentifikasi modus kegagalan dan memprediksi kapasitas lentur balok beton bertulang FRP. Berbagai macam basis data eksperimen disurvei dan digunakan sebagai masukan untuk kerangka kerja ML, sehingga mampu mempelajari dan mengidentifikasi pola yang mengendalikan modus kegagalan dan kapasitas lentur.

Algoritma SVM dan k-nearest neighbor (K-NN) digunakan untuk mengklasifikasikan modus kegagalan yang diamati dalam eksperimen, yaitu penghancuran beton dan pecahnya FRP. Akhirnya, model prediksi GEP yang menghubungkan mode kegagalan yang teridentifikasi

dikembangkan untuk memprediksi kapasitas lentur balok bertulang FRP. Ekspresi yang diusulkan merupakan fungsi dari sifat geometris balok dan sifat material beton serta batang FRP.

3.2 BASIS DATA EKSPERIMENTAL

Umumnya, ML membutuhkan data masukan atau pelatihan untuk pembelajaran dan pengenalan pola. Untuk mengklasifikasikan mode kegagalan dan mengembangkan model prediksi menggunakan GEP, literatur yang ada disurvei secara ekstensif dan data eksperimen dari total 164 balok bertulang FRP yang diuji dalam lentur dikumpulkan. Pengumpulan data dilanjutkan dengan mengidentifikasi parameter kritis yang mengatur perilaku lentur.

Basis data yang dikumpulkan terdiri dari sifat geometris balok yang diuji, termasuk lebar balok (b_w), kedalaman (h), kedalaman efektif (d), dan rasio tulangan (ρ); selain sifat material, termasuk kuat tekan beton (f'_c), modulus elastisitas FRP (EFRP), dan kuat tarik FRP ($f_{ult,FRP}$). Selain itu, basis data eksperimen mencakup mode kegagalan yang teridentifikasi dalam eksperimen. Ringkasan data eksperimen yang dikumpulkan dan berbagai variabel disajikan pada Tabel 3.1. Distribusi variabel dan mode kegagalan ditunjukkan pada Gambar 3.1.

Pengumpulan data ini dilanjutkan dengan **identifikasi parameter kritis** yang berpengaruh terhadap perilaku lentur balok FRP. Beberapa parameter utama yang diperhatikan antara lain dimensi balok seperti lebar, tinggi, dan panjang; kuat tekan beton (f'_c) yang menunjukkan kemampuan beton menahan gaya tekan; rasio tulangan FRP (ρ_{frp}) yang menggambarkan kontribusi tulangan terhadap kekuatan tarik; serta sifat mekanis FRP, meliputi modulus elastisitas (E) dan kuat tarik ultimit (f_{frp}), yang sangat menentukan daya tahan material terhadap regangan. Selain itu, data juga mencatat mode kegagalan yang terjadi, apakah dominan berupa keruntuhan tarik, tekan, atau kombinasi keduanya. Seluruh parameter tersebut kemudian digunakan sebagai variabel masukan dalam proses pelatihan model GEP.

Pentingnya basis data eksperimen ini terletak pada kemampuannya untuk meningkatkan reliabilitas dan akurasi model prediksi. Melalui data yang lengkap dan representatif, peneliti dapat melakukan validasi dengan membandingkan hasil prediksi model terhadap data empiris. Hal ini tidak hanya memastikan keakuratan model, tetapi juga memungkinkan penggalan pola hubungan antara variabel input dan respons struktur, misalnya kapasitas lentur atau mode kegagalan yang terjadi. Lebih jauh, basis data semacam ini juga dapat berfungsi sebagai *benchmark* yang berguna bagi penelitian lanjutan, baik untuk pengembangan metode komputasi baru maupun untuk verifikasi hasil uji eksperimen selanjutnya. Dengan demikian, keberadaan basis data yang kuat dan terstruktur memungkinkan penerapan ML melalui GEP menghasilkan model prediksi yang lebih akurat, dapat diandalkan, serta mampu digeneralisasi untuk berbagai kondisi balok FRP yang mungkin sulit diuji secara langsung di laboratorium.

Secara khusus, **Gene Expression Programming (GEP)** merupakan salah satu metode evolusioner dalam kecerdasan buatan yang dikembangkan untuk menemukan hubungan

matematis atau persamaan prediksi dari data kompleks. GEP bekerja dengan cara yang terinspirasi dari proses genetika, yaitu membangkitkan, memodifikasi, dan menyeleksi populasi solusi hingga ditemukan model yang paling optimal. Keunggulan GEP dibanding metode lain, seperti regresi linier atau bahkan beberapa algoritma ML klasik, terletak pada fleksibilitasnya dalam menemukan pola non-linear yang tersembunyi dalam data, serta kemampuannya menghasilkan persamaan eksplisit yang mudah ditafsirkan. Dalam konteks balok FRP, GEP dapat memproses variabel-variabel masukan seperti dimensi balok, kuat tekan beton, rasio tulangan, dan sifat mekanis FRP untuk menghasilkan model matematis yang mampu memprediksi kapasitas lentur maupun mode kegagalan dengan tingkat keakuratan tinggi.

Oleh karena itu, penggunaan GEP berbasis basis data eksperimen yang luas tidak hanya memberikan nilai tambah bagi dunia akademik, tetapi juga memiliki implikasi praktis bagi dunia rekayasa struktur. Misalnya, hasil model dapat membantu insinyur dalam merancang balok FRP dengan prediksi kinerja yang lebih tepat, sehingga efisiensi desain dapat ditingkatkan tanpa harus selalu melakukan uji laboratorium yang memakan biaya dan waktu. Dengan kata lain, integrasi antara data eksperimen, ML, dan metode GEP menjadi langkah strategis menuju rekayasa struktur yang lebih modern, efisien, dan berbasis data.


3.3 PEMBELAJARAN MESIN BERBASIS DATA UNTUK PREDIKSI RESPONS

Dalam studi ini, algoritma Pembelajaran Mesin (ML) diterapkan untuk memprediksi mode kegagalan dan kapasitas lentur balok beton bertulang FRP. Untuk mencapai hal ini, kerangka kerja ML yang diilustrasikan pada Gambar 3.2 digunakan. Kerangka kerja ini terdiri dari tiga tahap yang meliputi pengumpulan data, klasifikasi mode kegagalan, dan prediksi kapasitas. Tahap pengumpulan data melibatkan pengumpulan data eksperimen yang mencakup berbagai parameter (fitur) yang mengatur perilaku seperti yang telah dibahas sebelumnya (Tabel 3.1).

Tabel 3.1: Ringkasan basis data eksperimen yang disurvei.

Referensi	#daries	Lebar (mm)	Kedalaman (mm)	$f'_c (MPa)$	Rnft Rasio	E, GPa	$f_{ult} MPa$	Mode Kegagalan
Almusallam et al., 1997	4	200	240	33–36	1.33	43	885	C
Therriault & Benmokrane, 1998	8	130	180	46–97	1.19–2.79	38	773	C
Toutanji & Saafi, 2000	6	180	300	35	0.53–1.1	40	695	C
Kassern et al., 2011	12	200	300	39–41	0.55–2.24	36–122	617–1988	C
Benmokrane et al., 1995	9	200	300–550	43–52	0.57–1.12	42–49	641–689	C, T
Ashour, 2006	6	150	200–300	28–50	0.14–0.28	38	650	T

Benmokrane & Masmoudi, 1996	3	200	300–550	43	0.57–1.13	45	600	C, T
Yost et al., 2001	12	191–381	152–216	28	0.12–1.35	41	830	C, T
Masmoudi et al., 1998	8	200	300	45–52	0.68–2.23	38	773	C
Brown & Bartholomew, 1993	5	152	152	36	0.37	45	760	T
Duranovic et al., 1997	3	150	250	25–32	1.34	45	1000	C
Alsayed et al., 2000	6	200	210–300	31–41	1.15–3.6	36	700	C
Bischoff, 2005	2	152	152	49–52	0.32–0.50	140	1900	C
El-Nemr et al., 2013	12	200	400	29–73	0.38–1.82	49–69	1639	C, T
Faza & GangaRao, 1993	6	152	305	29–45	0.87–2.49	46–51	552–896	C
Wang & Belarbi, 2005	3	178	229	48	0.67–3.39	41–124	552–2069	C
Lau & Pam, 2010	5	280	380	34–43	0.35–2.07	38–40	582–603	C, T
Gao & Benmokrane, 2001	3	200	270–294	39–54	0.59–2.95	38–49	513–773	C, T
El Refai et al., 2015	3	230	300	40	0.41–1.08	50	1000	C, T
Alkhraisha et al., 2020	6	180	230	30	0.34–1.29	43–47	1075–1121	C
Abed et al., 2021	10	180	230	47–70	0.51–1.94	43–130	1029–2068	C
Maranan et al., 2015	17	200	400	29–48	0.38–1.87	47–69	666–1639	C
Habeeb & Ashour, 2008	5	200	300	24–28	0.16–0.42	200	1061–2000	T



Gambar 3.1: Distribusi variabel dalam basis data eksperimen yang dikumpulkan.

Setelah pemilihan fitur, algoritma klasifikasi, yang dalam hal ini menggunakan SVM dan K-NN, digunakan untuk mengklasifikasikan mode kegagalan yang diamati dalam eksperimen. Pada langkah terakhir, persamaan prediktif untuk setiap klasifikasi mode kegagalan dikembangkan menggunakan algoritma GEP. Penjelasan rinci tentang langkah-langkah ini disediakan dalam subbagian di bawah ini.

Klasifikasi Mode Kegagalan

Dalam penelitian ini, algoritma SVM dan k-nearest neighbor (K-NN) digunakan untuk mengklasifikasikan mode kegagalan balok bertulang FRP yang diamati dalam eksperimen.

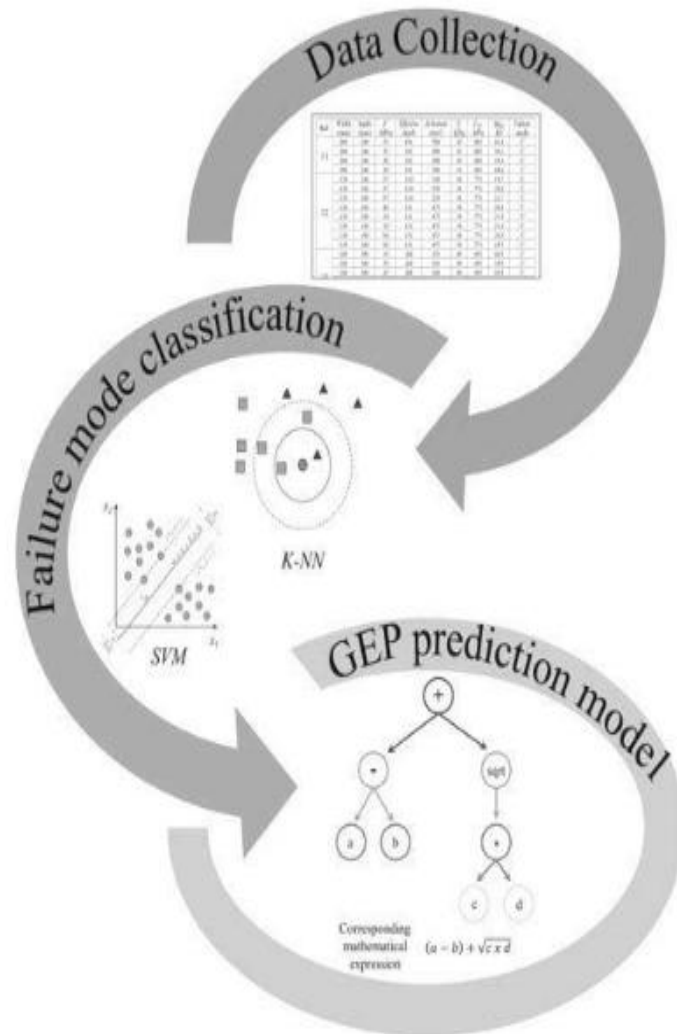
Mesin Vektor Pendukung

SVM adalah salah satu algoritma pembelajaran mesin (ML) yang paling dikenal dan awalnya diusulkan untuk klasifikasi biner. Solusinya melibatkan pengembangan hiperplan pemisah antara dua kelas. Hal ini dilakukan dengan memaksimalkan lebar margin antara hiperplan keputusan dan data berlabel (yaitu, dengan mode kegagalan yang diketahui) secara bersamaan dan meminimalkan kesalahan klasifikasi data. Untuk mengilustrasikan hal ini, perhatikan hiperplan pemisah yang didefinisikan sebagai.

$$w^T x + b = 0 \quad (3.1)$$

di mana w adalah vektor pembobot yang menentukan arah batas margin, sedangkan b mewakili bias. Dengan demikian, fungsi keputusan dapat didefinisikan sebagai berikut:

$$f(x) = \text{sgn}(w^T x + b) = \begin{cases} 1, & w^T x + b \geq 0 \\ -1, & w^T x + b < 0 \end{cases} \quad (3.2)$$




Gambar 3.2: Skema kerangka kerja ML untuk prediksi mode kegagalan dan kapasitas lentur balok bertulang FRP.

Algoritma SVM mencoba memaksimalkan margin dengan meminimalkan norma L_2 dari w (yaitu, $\|w\|$), hal ini menghasilkan masalah optimasi terkendala berikut.

$$\begin{aligned}
 & \min_{w, \xi} \left[\frac{1}{2} \|w\|^2 + \sum_{i=1}^M \xi_i \right] \\
 \text{s.t} \quad & y_i(w^T + b) \geq 1 - \xi_i \\
 & \xi_i > 0 \\
 & C > 0
 \end{aligned} \tag{3.1}$$

di mana ξ_i adalah variabel slack yang diperkenalkan untuk mengakomodasi beberapa pelanggaran batasan (beberapa titik data di dalam margin). Jika pemisahan data secara linear tidak memungkinkan, solusi alternatifnya adalah menggunakan trik kernel yang memproyeksikan titik-titik data ke dimensi yang lebih tinggi di mana data dapat dipisahkan secara linear (lihat Gambar 3.3).



Gambar 3.3: Contoh penerapan trik kernel pada data yang dapat dipisahkan secara nonlinier.

Fungsi kernel $K(x_i, x_j)$ didefinisikan sebagai produk titik fungsi sebagai berikut,

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (3.4)$$

di mana x_i dan x_j adalah fitur data. Dalam SVM, fungsi kernel yang umum digunakan adalah:

- Linier Kernel, $K(x_i, x_j) = x_i^T x_j$
- Polinomial Kernel, $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d$
- Radial basis function (RBF) atau Gaussian kernel, $K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / 2\sigma^2)$
- Sigmoid Kernel, $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

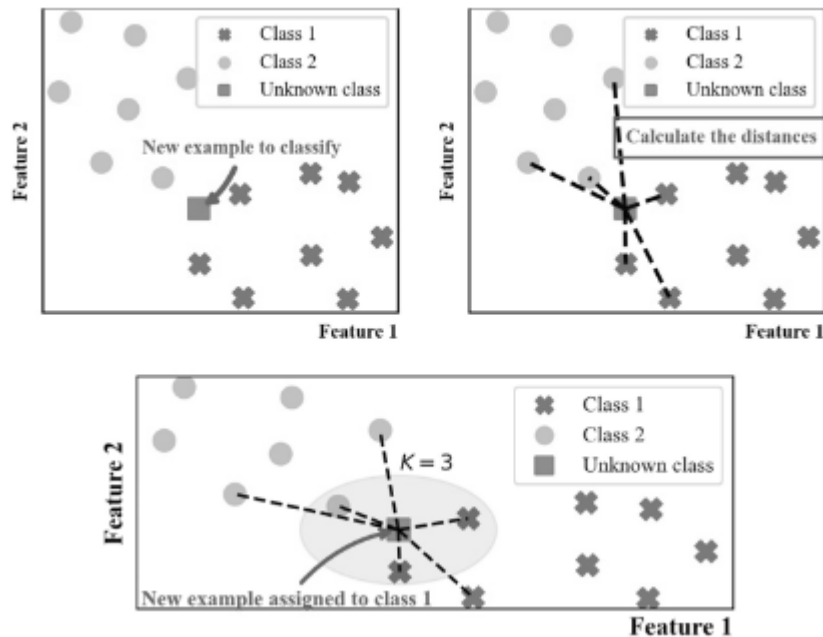
di mana γ, r, σ , dan d adalah parameter kernel. Parameter kernel γ harus lebih besar dari nol. Kernel linear adalah yang paling sederhana dan hanya memiliki satu parameter C (lihat Persamaan 3.3) yang merupakan parameter regularisasi atau penalti yang mengontrol trade-off antara memaksimalkan lebar margin dan meminimalkan kesalahan klasifikasi (Tharwat, 2019). Penggunaan kernel linear setara dengan algoritma yang tidak menggunakan kernel apa pun.

Fungsi basis radial (RBF) atau kernel Gaussian hanya memiliki satu parameter σ yang mengontrol kinerja SVM. RBF memiliki banyak varian yang memiliki perilaku sensitivitas yang berbeda terhadap perubahan parameter σ . Misalnya, kernel Laplacian yang didefinisikan sebagai $K(x_i, x_j) = \exp(-\|x_i - x_j\| / 2\sigma)$ kurang terpengaruh oleh perubahan parameter σ . Varian lain dari kernel RBF adalah kernel eksponensial yang didefinisikan sebagai $K(x_i, x_j) = \exp(-\|x_i - x_j\| / 2\sigma^2)$, satu-satunya perbedaan antara kernel eksponensial dan kernel RBF adalah kernel RBF mencakup kuadrat norma.

Biasanya, algoritma SVM mencakup langkah-langkah berikut:

1. Transformasi dan penskalaan data sesuai kebutuhan paket SVM.
2. Pertimbangkan kernel tertentu (misalnya, kernel RBF).
3. Dapatkan parameter kernel optimal melalui validasi silang (misalnya, untuk RBF, parameternya adalah σ dan C).

4. Gunakan parameter optimal untuk melatih seluruh set pelatihan.
5. Uji model yang dihasilkan menggunakan set data uji.



Gambar 3.4: Deskripsi grafis algoritma K-NN.

K-Nearest Neighbor

K-NN adalah algoritma klasifikasi. Proses K-NN melibatkan penghitungan jarak antara setiap dua vektor fitur (x_i, x_j) dari set data pelatihan. Kemudian, jarak ini dan kelas yang bersesuaian dengan x_i ditambahkan ke dalam koleksi terurut. Koleksi terurut ini disusun dalam urutan menaik berdasarkan jarak. Setelah itu, K entri pertama dari koleksi terurut yang telah diurutkan dipilih. Kemudian, kelas yang bersesuaian dengan vektor fitur x_i ditentukan sebagai modus dari K kelas.

Algoritma ini bertujuan untuk mengevaluasi K optimal yang mengurangi kesalahan klasifikasi dengan mencoba beberapa K dan memilih salah satu yang optimal. Deskripsi grafis konsep K-NN diilustrasikan pada Gambar 3.4. Seperti yang ditunjukkan pada gambar, untuk mengidentifikasi kelas dari contoh yang tidak diketahui, jarak antara contoh yang tidak diketahui dan semua titik tetangga lainnya dihitung terlebih dahulu. Aturan klasifikasi K-NN adalah menetapkan contoh yang tidak diketahui ke dalam kelas yang mencakup sebagian besar dari K contoh pelatihan terdekat.

Jarak Euclidean antara contoh pengujian dan contoh pelatihan yang ditentukan adalah yang paling banyak digunakan dalam algoritma klasifikasi K-NN. Misalkan x_i adalah contoh pengujian dengan k fitur $(x_{i1}, x_{i2}, \dots, x_{ik})$ dan n adalah jumlah total contoh pelatihan yang ditentukan, masing-masing memiliki k fitur. Jarak Euclidean antara x_i dan $x_j = (x_{j1}, x_{j2}, \dots, x_{jk})$ di mana $j = 1, 2, \dots, n$ didefinisikan sebagai (Zhang dan Zhou, 2007; Yu dkk., 2001):

$$D(x_i, x_j) = \sqrt{(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \dots + (x_{ik} - x_{jk})^2} \quad (3.5)$$

Hasil Klasifikasi

Dataset yang dikumpulkan, yang dijelaskan pada Tabel 3.1, digunakan sebagai masukan untuk kerangka kerja ML. Dataset ini dibagi secara acak menjadi tiga set: set pelatihan, set pengujian, dan set validasi. Set pelatihan digunakan untuk melatih algoritma klasifikasi (untuk mengembangkan model prediktif), set validasi digunakan untuk mengkalibrasi parameter model, dan set pengujian digunakan untuk mengevaluasi kinerja model yang dikembangkan. Untuk mengimplementasikan algoritma SVM dan K-NN, dataset diklasifikasikan menjadi dua kelas: kelas yang dikontrol tarik dan kelas yang dikontrol tekan, dengan fitur masukan x_1, x_2, \dots, x_6 merupakan variabel yang mengontrol perilaku balok beton bertulang FRP.

Tabel 3.2: Akurasi klasifikasi SVM.

Tipe SVM	Klasifikasi Akurasi
Linier	92,7%
Quadratic	97,0%
Kubik	93,9%
Gaussian yang bagus	92,1%
Gaussian Sedang	95,1%
Gaussian Kasar	78,7%

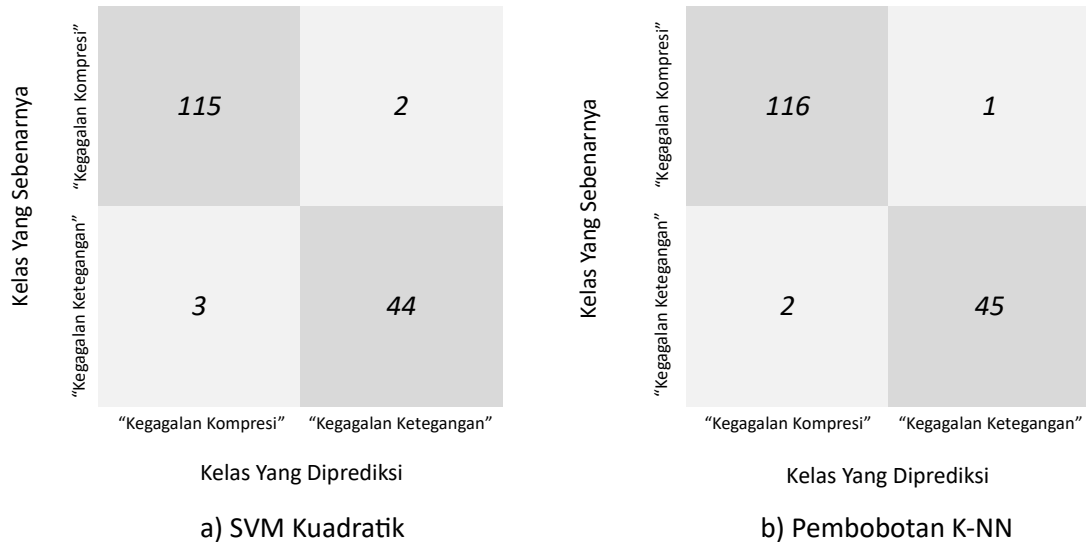
Tabel 3.3: Akurasi klasifikasi K-NN.

Tipe K-NN	Klasifikasi Akurasi
Bagus	97,0%
Sedang	83,5%
Kasar	71,3%
Kosinus	78,7%
Kubik	81,7%
Tertimbang	98,2%

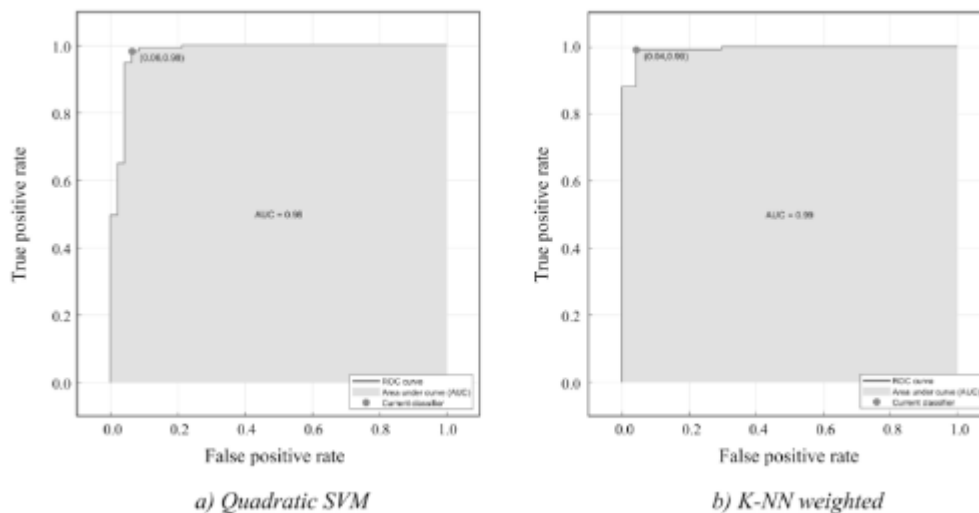
Perangkat lunak MATLAB® digunakan untuk mengimplementasikan algoritma SVM dan K-NN. Akurasi klasifikasi masing-masing pengklasifikasi ditunjukkan pada Tabel 3.2 dan 3.3 untuk algoritma SVM dan K-NN. Akurasi klasifikasi merepresentasikan jumlah contoh yang terklasifikasi dengan benar dalam set pelatihan terhadap jumlah total contoh dalam set ini. Seperti ditunjukkan pada Tabel 3.2, kernel kuadrat memiliki kinerja terbaik; oleh karena itu, kernel tersebut digunakan untuk mengevaluasi kinerja model SVM pada set pengujian. Lebih lanjut, Tabel 3.3 menunjukkan bahwa tipe K-NN terbobot menghasilkan kinerja klasifikasi terbaik; oleh karena itu, kernel tersebut digunakan untuk menilai set pengujian.

Untuk menilai kinerja setiap pengklasifikasi pada set pengujian, matriks konfusi yang berisi informasi tentang klasifikasi yang diprediksi dan teramati dikembangkan seperti yang ditunjukkan pada Gambar 3.5a dan Gambar 3.5b untuk SVM dengan kernel kuadrat dan K-NN terbobot. Di sini, klasifikasi yang teramati merepresentasikan mode kegagalan aktual yang

diamati dalam eksperimen pada balok beton bertulang FRP, sementara klasifikasi yang diprediksi merepresentasikan yang diprediksi oleh pengklasifikasi yang dikembangkan.



Gambar 3.5: Matriks kebingungan klasifikasi (a) SVM kuadrat (b) terbobot K-NN.



Gambar 3.6: Matriks kebingungan klasifikasi (a) SVM kuadrat (b) K-NN terbobot.

Suku diagonal (berwarna hijau) dari matriks kebingungan merepresentasikan contoh uji yang terklasifikasi dengan benar (mode kegagalan yang teramati sama dengan yang diprediksi) sementara suku di luar diagonal (berwarna merah) merepresentasikan contoh yang salah diklasifikasikan. Seperti yang ditunjukkan pada Gambar 3.5b, K-NN terbobot berkinerja sedikit lebih baik daripada SVM kuadrat dalam memprediksi mode kegagalan pada set uji. Untuk menilai lebih lanjut setiap algoritma, kurva karakteristik operasi penerima (ROC) diplot dan disajikan pada Gambar 3.6a dan Gambar 3.6b untuk algoritma SVM dan K-NN, masing-masing. Area di bawah kurva ROC merepresentasikan metrik yang dapat digunakan untuk menilai kinerja pengklasifikasi pada pengujian. Seperti yang ditunjukkan pada Gambar 3.6, area di

bawah kurva ROC yang bersesuaian dengan K-NN terbobot lebih tinggi dibandingkan dengan area di bawah kurva ROC yang bersesuaian dengan algoritma SVM; Dengan demikian, K-NN memiliki kinerja yang lebih baik.

Model Prediksi Kapasitas Lentur GEP

Pada tahap ketiga kerangka kerja ML yang diadopsi dan setelah klasifikasi mode kegagalan, GEP digunakan untuk mengembangkan model prediksi kapasitas lentur balok bertulang FRP yang terkait dengan setiap mode kegagalan. GEP dipresentasikan oleh Ferreira, yang menggabungkan pemrograman genetik dengan algoritma genetika. GEP meniru seleksi alam Darwinian dalam evolusi ekspresi. Mesin GEP mampu menghasilkan kode prediksi yang robust yang dapat diekspresikan dalam bentuk pohon ekspresi atau rumus matematika (Gambar 3.7), yang membuatnya cocok untuk membuat model prediksi untuk berbagai jenis permasalahan.

Setiap proses GEP melibatkan lima komponen: (1) himpunan fungsi yang mencakup operasi matematika yang akan digunakan; (2) himpunan terminal yang menunjukkan representasi simbolis variabel; (3) fungsi kebugaran yang mengevaluasi seberapa cocok kromosom terhadap sisa populasi (kromosom) seperti root mean square error (RMSE) Persamaan 3.6, (4) parameter kontrol; dan (5) kondisi terminasi. Gambar 3.8 mengilustrasikan algoritma GEP yang mengembangkan pohon ekspresi. Algoritma dimulai dengan memilih lima komponen yang disebutkan sebelumnya. Populasi awal kromosom dihasilkan secara acak menggunakan set fungsi yang telah ditentukan dan terminal.

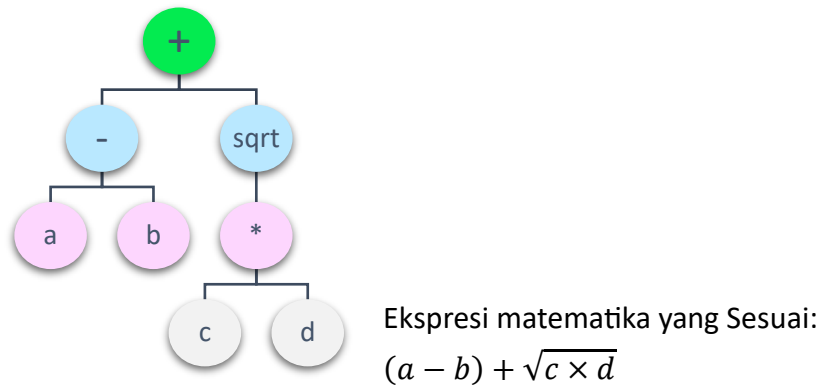
Kromosom yang dihasilkan dieksekusi dan diubah menjadi ekspresi pohon. Hasil ekspresi dibandingkan dengan data aktual menggunakan fungsi kebugaran dan jika hasilnya memuaskan, proses dihentikan. Namun, jika tingkat kebugaran yang diinginkan tidak tercapai, variasi dalam populasi diperkenalkan dengan melakukan satu atau lebih operator genetik (crossover, mutasi, atau rotasi) pada kromosom yang dipilih. Individu-individu dipilih dan disalin ke generasi berikutnya sesuai dengan kebugaran dengan pengambilan sampel roda roulette dengan elitisme.

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^n (v_{test} - v_{predicted})^2} \quad (3.6)$$

Fitur yang diekstraksi dari database dan disertakan dalam pengembangan model prediksi adalah lebar balok b , kedalaman efektif balok d , kuat tekan silinder beton f'_c , rasio tulangan ρ , modulus elastisitas FRP E , dan kuat tarik FRP f_{ult} . Selain itu, berbagai parameter terlibat dalam pengembangan model GEP; parameter ini memengaruhi kemampuan generalisasi model yang dikembangkan. Parameter yang dipilih untuk algoritma GEP ditunjukkan pada Tabel 3.4. Pemilihan parameter didasarkan pada beberapa percobaan.

Dalam setiap percobaan, satu variabel bervariasi sementara yang lain tetap konstan. Percobaan dibandingkan berdasarkan koefisien variasi (COV) dan rata-rata rasio yang diuji

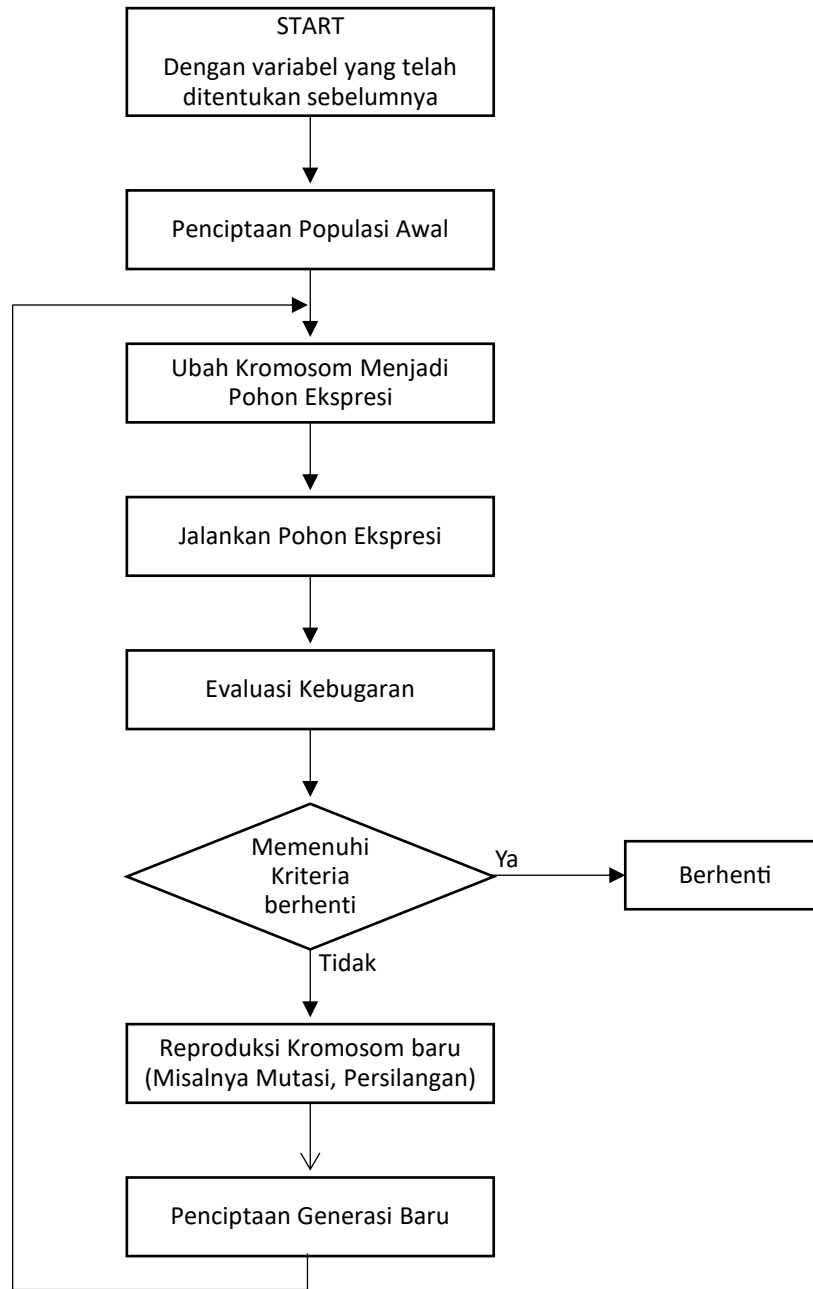
terhadap yang diprediksi ($M_{u,tes}/M_{u,prediksi}$). Dalam mengembangkan model prediksi, operasi matematika dasar dipilih dalam set fungsi untuk menghasilkan model sederhana.



Gambar 3.7: Eksresi pohon dan eksresi matematika yang sesuai.

Tabel 3.4: Parameter terpilih GEP.

Parameter	Nilai Yang dipilih
Variabel dependen (tegangan geser)	1
Variabel Independen	5
Gen	3, 4
Kumpulan Fungsi	$-, +, \times, \div, \sqrt{x}, \sqrt[3]{x}, x^x, \exp x$
Ukuran Kepala	6,7
Fungsi penghubung Atnat ET's	Multiplikasi

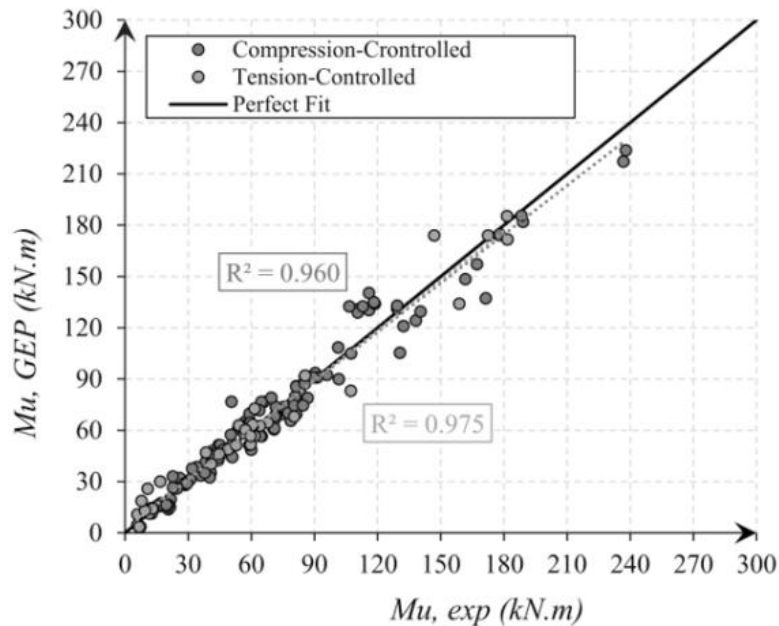


Gambar 3.8: Algoritma evolusi ekspresi gen.

Tabel 3.5: Model GEP turunan untuk memprediksi kapasitas lentur balok bertulang FRP.

Mode Kegagalan	Model Prediksi GEP	R^2
Penghancuran Beton	$Y = \frac{1}{\left((b + 8.21) - (2f'c) \right) + (b + 5.05)} \times \left(\left(\left(\frac{d}{1.134} \right) + e^{6.27} \right) - ((11.16 + b) \times 5.89) \right) \times \frac{d}{(5.98 \times 5.98)^2} \times \frac{E}{-0.22} \times ((\rho \times 8.08) + 40.06 - d) \times \rho^{0.5}$	0.96

Pecahnya FRP	$y = \left(\sqrt[3]{f'c} \times (3.6 \times 2.684) - (d - f'c) \times 0.416 \right) \times \frac{\sqrt[6]{10^{-9.28}}}{(-1.614 \times -5.225) + (-5.22^2)} \times \left(E - \left(d + ((2\rho) \times (b + f_{ult})) \right) \right)$	0.98
--------------	--	------



Gambar 3.9: Kapasitas lentur ultimit eksperimen vs. prediksi untuk mode kegagalan penghancuran beton dan pecahnya FRP.

Basis data yang disurvei dibagi menjadi dua set: set kegagalan akibat remuk beton (117 pengujian) dan set kegagalan akibat pecahnya FRP (47 pengujian). Setiap set data dibagi menjadi set pelatihan dan set validasi untuk memastikan generalisasi model. Model GEP yang dikembangkan untuk setiap mode kegagalan dan koefisien determinasi (R^2) terkait tercantum dalam Tabel 3.5 dan ditunjukkan pada Gambar 3.9. Model GEP untuk kegagalan yang dikontrol kompresi menghasilkan RMSE sebesar 9,45 $kN.m$, sedangkan model yang dikontrol tarik menghasilkan 8,56 $kN.m$.

3.4 PERBANDINGAN PERMODELAN


Untuk menilai akurasi prediksi dan memvalidasi kerangka kerja yang diusulkan, kapasitas lentur yang diperoleh menggunakan model prediksi dibandingkan dengan pedoman desain ACI 440-15 dan CSA S806-12. Klasifikasi mode kegagalan dan penentuan prosedur kapasitas lentur untuk kedua pedoman desain dirangkum dalam Tabel 3.6.

Tabel 3.6: Klasifikasi dan prosedur prediksi kapasitas lentur untuk pedoman ACI 440 dan CSA S806.

ACI 440-15	CSA S806-12
$\rho_f = \frac{A_f}{bd}$	$\rho_f = \frac{A_f}{bd}$
$\beta_1 = \begin{cases} 17 \leq f'_c \leq 28, & \beta_1 = 0.85 \\ 28 < f'_c < 55, & \beta_1 = -\frac{0.05(f'_c - 28)}{7} \\ f'_c \geq 55, & \beta_1 = 0.65 \end{cases}$	$\alpha_1 = 0.85 - 0.0015f'_c$
Ketika $\rho_f > \rho_b$ (Menghancurkan Beton)	$\beta_1 = 0.85 - 0.0025 f'_c$
$f_f = \sqrt{\frac{(E_f \varepsilon_{cu})^2}{4} + \frac{0.85\beta_1 f'_c}{\rho_f} E_f \varepsilon_{uc} - 0.5E_f \varepsilon_{cu}} \leq f_{fu}$	Ketika $\rho_f > \rho_b$ (Menghancurkan Beton)
$M_u = \rho_f f_f b d^2 \left(1 - 0.59 \frac{\rho_f f_f}{f_c}\right)$	$\alpha_1 \beta_1 f'_c - A_f E_f \varepsilon_{cu} \frac{d-c}{c} = 0$
Ketika $\rho_f > \rho_b$ (FRP Pecah)	$f_f = E_f \varepsilon_{cu} \frac{d-c}{c} < f_{fu}$
$c_b = \left(\frac{\varepsilon_{cu}}{\varepsilon_{cu} + \varepsilon_{cu}}\right) d$	$M_u = \rho_f f_f b d^2 \left(1 - \frac{\rho_f f_f}{2\alpha_1 f'_c}\right)$
$M_u = A_f f_{fw} \left(d - \frac{\beta_1 c_b}{2}\right)$	Ketika $\rho_f > \rho_b$ (Menghancurkan Beton) Keadaan batas pengendalian dalam standar ini adalah kegagalan tekan dan hanya berlaku untuk balok mode kegagalan penghancuran beton.
$\varepsilon_{cu} = 0.003$	$\varepsilon_{cu} = 0.0035$

Sebagaimana disebutkan sebelumnya, CSA S806-12 hanya memperhitungkan mode kegagalan penghancuran beton. Pedoman klasifikasi ACI 440-15 dan CSA S806-12, yang didasarkan pada rasio tulangan seimbang, menghasilkan akurasi 94% dan 95% dalam memprediksi mode kegagalan, dibandingkan dengan akurasi 99% saat menggunakan algoritma K-NN.

Gambar 3.10 menunjukkan kapasitas lentur eksperimental versus yang diprediksi menggunakan CSA S806, ACI 440, dan metode berbasis pembelajaran mesin yang diusulkan. Meskipun hasilnya tidak menunjukkan perbedaan akurasi yang signifikan, model berbasis ML memberikan akurasi tertinggi dengan RMSE keseluruhan sebesar 9,2 kN.m dibandingkan dengan RMSE sebesar 11,6 dan 11,1 kN.m untuk CSA S806 dan ACI 440. Selain itu, dalam hal Koefisien Determinasi (R^2), model yang diusulkan memberikan $R^2 = 0,97$ dibandingkan dengan $R^2 = 0,95$ untuk CSA S806 dan ACI 440.



Gambar 3.10: Kapasitas lentur ultimit eksperimental vs. prediksi menggunakan CSA S806, ACI 440, dan kerangka kerja ML yang diadopsi.

3.5 KESIMPULAN

Studi ini menggunakan kerangka kerja pembelajaran mesin hibrida untuk memprediksi mode kegagalan dan kapasitas lentur balok beton bertulang FRP. Kerangka kerja ini dibagi menjadi tiga tahap: pengumpulan data, klasifikasi mode kegagalan, dan pengembangan model prediksi ekspresi gen. Berdasarkan hasil studi, kesimpulan berikut dapat ditarik:

1. Metode klasifikasi berbasis pembelajaran mesin, SVM dan K-NN, dapat dianggap efektif dan andal dalam memprediksi mode kegagalan balok beton bertulang FRP dengan akurasi tinggi. Metode K-NN menghasilkan akurasi klasifikasi sebesar 99% dibandingkan dengan 94% dan 95% untuk prosedur ACI 440 dan CSA S806, yang didasarkan pada rasio tulangan seimbang.
2. Meskipun akurasi prosedur ACI 440 dan CSA S806 tinggi, model prediksi kapasitas lentur GEP yang diusulkan memberikan akurasi yang lebih tinggi dengan R^2 keseluruhan sebesar 0,97 dan RMSE sebesar 9,2 kN.m.
3. Kerangka kerja ML menyediakan pendekatan yang fleksibel, andal, dan cepat untuk mengklasifikasikan dan memprediksi kapasitas lentur balok FRP-RC. Kerangka kerja yang diadopsi dapat diterapkan pada berbagai aplikasi rekayasa struktur.
4. Meskipun standar CSA S806 tidak memperbolehkan perancangan balok bertulang FRP dengan mode kegagalan patah FRP, kerangka kerja yang diusulkan telah menunjukkan bahwa mode kegagalan patah FRP dan kapasitas momen yang sesuai dapat diprediksi dengan akurasi tinggi.

BAB 4

PEMROGRAMAN EKSPRESI GENETIK BETON

4.1 PENDAHULUAN

Banyak permasalahan desain dalam teknik sipil dapat dideskripsikan sebagai pencarian opsi terbaik di antara serangkaian alternatif. Salah satu permasalahan tersebut adalah desain campuran beton, di mana proporsi bahan-bahan harus dipilih sedemikian rupa untuk mengoptimalkan sifat mekanis beton tertentu. Proses ini melibatkan estimasi fungsi regresi yang memodelkan hubungan antara variabel target dan serangkaian prediktor yang terdiri dari bahan-bahan campuran dan variabel relevan lainnya seperti suhu dan umur beton. Secara umum, model yang menunjukkan kesesuaian paling dekat dengan hasil pengamatan eksperimental dianggap sebagai solusi optimal.

Mengidentifikasi model terbaik dapat menjadi rumit jika bentuk matematika dari fungsi regresi tidak diketahui, atau fungsi tujuan mengandung beberapa optima lokal. Dalam kasus seperti itu, algoritma yang dimotivasi secara matematis seperti penurunan gradien tidak dapat diterapkan atau tidak efisien. Algoritma metaheuristik yang berupaya menemukan solusi mendekati optimal dalam waktu yang wajar baru-baru ini muncul sebagai pendekatan yang layak untuk memecahkan masalah optimasi yang rumit. Banyak algoritma metaheuristik yang terinspirasi oleh alam; mereka meniru perilaku hewan atau proses alami seperti evolusi untuk memecahkan masalah optimasi di mana fungsi tujuannya terputus-putus, nonlinier, atau tidak dapat diturunkan.

Algoritma metaheuristik dapat diklasifikasikan dalam beberapa cara. Salah satu pendekatannya adalah dengan mengkarakterisasi algoritma tersebut sebagai berbasis populasi atau berbasis lintasan tergantung pada jumlah kandidat solusi yang dipertimbangkan pada setiap iterasi. Algoritma berbasis populasi menggunakan serangkaian string atau agen Algoritma genetika dan optimasi segerombolan partikel dianggap berbasis populasi. Di sisi lain, algoritma berbasis lintasan menggunakan satu kandidat solusi yang bergerak melalui ruang pencarian.

Contoh umum algoritma berbasis lintasan adalah simulasi anil, pencarian lokal berulang, dan pencarian lokal terpandu. Selain digunakan sebagai satu-satunya strategi optimasi, algoritma metaheuristik juga telah dipadukan dengan metode lain untuk menggabungkan manfaat dari berbagai strategi, menghasilkan metaheuristik hibrida. Selama dua dekade terakhir, berbagai algoritma metaheuristik telah digunakan dalam pelatihan jaringan saraf tiruan (JST), terutama yang bertipe umpan maju. Berbagai komponen JST seperti jumlah lapisan, jumlah simpul pada lapisan tersembunyi, dan bobot koneksi dapat ditentukan menggunakan optimasi metaheuristik. Pendekatan ini mengatasi keterbatasan algoritma penurunan gradien (misalnya, backpropagation) yang umum digunakan dalam JST konvensional.

Penggunaan algoritma evolusioner dalam perancangan JST merupakan bentuk umum metaheuristik hibrida yang menggabungkan kemampuan pencarian lokal algoritma

backpropagation dengan kemampuan pencarian global algoritma evolusioner. Karena JST telah berhasil memecahkan berbagai permasalahan teknik sipil/struktural, penggunaan GP dan ekstensinya, baik sebagai alternatif JST maupun sebagai bagian dari prosedur pelatihan JST, sedang dieksplorasi oleh para peneliti.

Dalam bab ini, kami mengeksplorasi penggunaan varian linier pemrograman gen (GP) yang disebut pemrograman ekspresi gen (GEP) dalam memprediksi sifat kekuatan beton kinerja tinggi (HPC). Sesuai namanya, HPC mengacu pada beton yang dirancang untuk memiliki kinerja yang lebih baik daripada beton konvensional. ACI Concrete Terminology (CT-18) mendefinisikan HPC sebagai "beton yang memenuhi kombinasi khusus persyaratan kinerja dan keseragaman yang tidak selalu dapat dicapai secara rutin menggunakan bahan-bahan konvensional dan praktik pencampuran, penempatan, dan perawatan normal".

Karena karakteristik beton yang diinginkan bersifat spesifik terhadap masalah, interpretasi yang tepat tentang makna HPC bergantung pada aplikasi dan lingkungan tertentu. Secara umum dipahami bahwa HPC menawarkan setidaknya satu dari sifat-sifat berikut: kekuatan tinggi, kekuatan awal tinggi, modulus elastisitas tinggi, permeabilitas rendah, penyusutan rendah, ketahanan tinggi terhadap abrasi, ketahanan tinggi terhadap bahan kimia berbahaya, daya tahan tinggi di lingkungan yang keras, ketangguhan dan ketahanan benturan tinggi, kemudahan penempatan dan pemadatan tanpa segregasi. Meskipun HPC sering disamakan dengan beton mutu tinggi, yang lebih disukai untuk jembatan dan gedung tinggi, kekuatan tinggi tidak diperlukan untuk penunjukan HPC. Ketahanan tinggi terhadap penetrasi klorida dan sistem rongga udara yang ditingkatkan dapat dicapai dalam beton mutu normal, sehingga mengurangi biaya material dalam desain jembatan.

Untuk mencapai ukuran kinerja yang diinginkan, selain bahan dasar beton tradisional (yaitu, semen Portland, air, agregat halus dan kasar), HPC mengandung bahan semen dan campuran kimia. Material semen seperti semen campuran, abu terbang, terak, dan asap silika ditambahkan ke dalam campuran untuk meningkatkan kekuatan dan daya tahan beton. Pereduksi air memungkinkan pengurangan kadar air hingga 12% dengan tetap mempertahankan tingkat konsistensi tertentu. Pengurangan kadar air hingga 30% dimungkinkan dengan menggunakan superplasticizer. Daya tahan, korosifitas, dan reaktivitas alkali-silika beton juga dapat dikontrol menggunakan campuran khusus.

Namun, bahan-bahan tambahan ini seringkali memodifikasi berbagai sifat beton selain sifat yang ditargetkan. Misalnya, pereduksi air seringkali memengaruhi waktu pengikatan awal. Beberapa pereduksi air mempercepat waktu pengikatan awal, sementara yang lain melakukan sebaliknya. Interaksi antara bahan-bahan dan pengaruhnya terhadap berbagai sifat belum sepenuhnya dipahami. Meskipun pengujian laboratorium dapat digunakan untuk menyelidiki sifat-sifat ini, eksperimen membutuhkan biaya mahal dan waktu yang lama. Karena HPC semakin banyak digunakan dalam berbagai aplikasi teknik sipil, memahami dan memodelkan perilaku HPC tetap menjadi tugas yang menantang. Sisa bab ini disusun sebagai berikut: Bagian selanjutnya merangkum pengetahuan tentang penggunaan optimasi metaheuristik dan pendekatan pembelajaran mesin untuk memprediksi kekuatan beton. Algoritma genetika dan perluasannya dibahas secara singkat di Bagian 3, dan komponen utama algoritma GEP

dijelaskan di Bagian 4. Model GEP untuk kuat tekan HPC dikembangkan di Bagian 5. Terakhir, Bagian 6 menyajikan kesimpulan dari studi ini.

4.2 MODEL BERBASIS KECERDASAN BUATAN UNTUK SIFAT HPC

Beton merupakan material yang sangat kompleks. Kekuatan dan daya tahannya ditentukan oleh berbagai faktor, termasuk bahan campuran dan proporsinya, teknik persiapan, kondisi pengeringan, dan usia. Karena campuran berkinerja tinggi mengandung berbagai bahan tambahan dan semen, memprediksi perilaku HPC lebih menantang daripada beton tradisional. Kesulitan ini mendorong penggunaan teknik kecerdasan buatan dalam pemodelan perilaku HPC. Karena hubungan fungsional yang menghubungkan faktor-faktor ini dengan sifat kekuatan dan daya tahan beton belum sepenuhnya dipahami, diperlukan model prediktif yang dikembangkan secara empiris. Karena penggunaan HPC yang terus-menerus, pengembangan metode komputasi lunak yang tepat untuk memprediksi sifat HPC menjadi penting.

Kekuatan tekan, sebagai salah satu sifat beton yang paling penting, telah menjadi subjek berbagai penelitian sejak awal tahun 1900-an. Salah satu model kekuatan tekan yang paling awal dan terkenal adalah hukum Abrams, yang menyatakan bahwa kekuatan beton meningkat seiring dengan penurunan rasio air terhadap semen. Sejak diperkenalkannya hukum Abrams, variabel-variabel tambahan telah ditemukan memengaruhi kuat tekan. Variabel-variabel ini meliputi rasio semen terhadap pasir, jumlah material semen, dan jenis semen.

Selain itu, terdapat pula studi eksperimental yang bertentangan dengan aturan Abrams. Misalnya, Popovics (1990) mengamati bahwa ketika dua campuran beton dengan rasio air-semen yang sama diuji, campuran dengan kadar semen yang lebih tinggi menghasilkan kekuatan yang lebih tinggi. Meskipun banyak literatur yang melaporkan hasil dari ribuan uji eksperimental yang mewakili berbagai campuran dan kondisi perawatan, sulit untuk menggeneralisasi hasil ini ke kasus lain.

Kualitas agregat kasar secara signifikan memengaruhi kinerja HPC, tidak seperti beton konvensional. Silica fume digunakan dalam HPC, dan jenis agregat dipilih dengan cermat, karena harus memiliki ukuran maksimum yang lebih kecil (10–14 mm) daripada yang digunakan dalam beton konvensional. Ukuran maksimum agregat yang lebih kecil dalam HPC membantu mengurangi tegangan diferensial yang dapat menyebabkan retakan mikro pada antarmuka pasta agregat-semen.

Selain itu, partikel agregat yang lebih kecil diketahui lebih kuat daripada yang lebih besar. Selama beberapa dekade terakhir, berbagai model prediktif telah dikembangkan untuk memodelkan karakteristik kekuatan beton tradisional dan beton kinerja tinggi mengembangkan salah satu model pertama untuk beton yang mengandung campuran pozzolan dan kapur, yang memerlukan penyesuaian parameter dan faktor pembobotan secara manual. Sifat kekuatan HPC juga telah diestimasi berdasarkan kerangka kerja yang didukung proses Gaussian.

Dalam studi lain, Nguyen dkk. (2021) menggunakan empat algoritma prediktif yang berbeda, regresi vektor pendukung, multilayer perceptron, regresor penguat gradien, dan

penguat gradien ekstrem untuk mengembangkan model prediktif untuk kekuatan tekan dan tarik HPC. Mousavi dkk. mengembangkan model prediksi untuk kuat tekan campuran HPC menggunakan pemrograman ekspresi gen, dan kombinasi pemrograman ekspresi gen dan kuadrat terkecil ortogonal.

Model ANN telah digunakan untuk memprediksi kinerja komposit yang terbuat dari baja, agregat daur ulang, dan jenis beton lainnya mengembangkan model berbasis ANN untuk memprediksi kuat tekan ultra HPC. Mereka mengamati peningkatan akurasi model ketika fitur dipilih secara berurutan. Latif (2021) menggunakan metode pembelajaran mendalam untuk memperkirakan kuat tekan HPC.

Metodologi permukaan respons orde tinggi dan pendekatan spline regresi adaptif multivariat juga telah ditemukan digunakan untuk memodelkan kinerja campuran beton. Kerangka kerja pembelajaran mesin untuk memperkirakan kapasitas geser dan modulus kegagalan ultra HPC. Para penulis menganalisis basis data menggunakan berbagai teknik pembelajaran mesin untuk mengidentifikasi faktor-faktor utama yang memengaruhi kapasitas geser dan modulus kegagalan HPC. Algoritma genetika dan varian serta perluasannya juga telah digunakan dalam pemodelan berbagai sifat beton.

Algoritma genetika dan JST adalah metode Kecerdasan Buatan, yang masing-masing termasuk dalam algoritma evolusioner dan metode pembelajaran mesin. Dibandingkan dengan JST tradisional, yang pada dasarnya merupakan kotak hitam dan hanya dapat menangani sebagian kecil masalah optimasi, algoritma genetika dan variannya menyediakan strategi optimasi global yang andal dan lebih transparan.

4.3 ALGORITMA GENETIKA DAN PERLUASANNYA

Algoritma Genetika (GA) adalah algoritma optimasi evolusioner yang diperkenalkan oleh Holland. Terinspirasi oleh teori evolusi Darwin, GA menggunakan operator yang meniru proses biologis seperti seleksi alam, persilangan, dan mutasi. GA adalah algoritma berbasis populasi yang memecahkan masalah optimasi dengan memanipulasi populasi kandidat solusi, di mana individu dipilih menggunakan fungsi kebugaran, dan generasi baru diperoleh menggunakan operator genetika.

Dibandingkan dengan algoritma optimasi berbasis gradien tradisional, GA menawarkan dua keunggulan utama. Pertama, kemampuan untuk menangani masalah kompleks dengan fungsi tujuan yang terputus-putus, nonlinier, bising, atau nonstasioner. Kedua, paralelisme, di mana ruang pencarian dieksplorasi oleh beberapa agen secara bersamaan, memungkinkan manipulasi parameter yang berbeda secara bersamaan. Algoritma Genetika (GA) sering kali menggunakan kombinasi strategi pencarian lokal dan global yang membantu memastikan konvergensi menuju optimum global. Istilah populasi mengacu pada himpunan solusi kandidat yang saat ini sedang dipertimbangkan dalam algoritma pencarian.

Setiap anggota populasi disebut individu dan direpresentasikan oleh kromosom, yang mengacu pada rangkaian gen. Dalam suatu permasalahan optimasi, GA menggunakan prosedur berikut untuk menemukan solusi yang baik: (1) mengodekan fungsi objektif; (2) mendefinisikan kriteria seleksi; (3) mendefinisikan populasi awal; (4) memperbarui populasi

secara iteratif menuju solusi yang lebih baik; (5) memperoleh solusi permasalahan dengan mendekodekan hasilnya. Setiap iterasi pembaruan populasi menghasilkan generasi baru.

Algoritma GA memerlukan seperangkat parameter dan fungsi yang ditentukan pengguna, yang harus dipilih secara cermat dengan mempertimbangkan permasalahan spesifik dan tujuan optimasi. Nilai optimal untuk parameter bergantung pada spesifikasi permasalahan optimasi, misalnya, sifat matematis fungsi objektif, di samping kualitas (representativitas) dan kuantitas data yang tersedia. Seperangkat parameter yang dipilih sangat memengaruhi efisiensi dan kinerja algoritma. Dalam Genetic Genetic Programming (GA) kanonik, setiap anggota populasi merupakan string karakter dengan panjang tetap, yang disebut kromosom, yang mengodekan solusi kandidat untuk masalah yang sedang dipertimbangkan.

Pemrograman Genetik (GP) merupakan perluasan dari GA di mana populasinya terdiri dari pohon parse dengan berbagai bentuk dan ukuran, di mana setiap pohon parse merepresentasikan program komputer atau persamaan yang menghasilkan solusi kandidat ketika dijalankan. GP dapat dipandang sebagai algoritma evolusioner yang menghasilkan program komputer dengan mencari ruang program, bukan ruang data. Keunggulan GP, dibandingkan dengan GA kanonik atau algoritma metaheuristik lainnya, adalah karena merupakan teknik optimasi simbolis, GP menyediakan ekspresi analitis yang sesuai dengan model, membuat replika lebih transparan, dan berpotensi lebih mudah diinterpretasikan.

Pemrograman ekspresi gen (GEP) adalah varian GA yang lebih baru, di mana setiap anggota populasi merupakan kromosom yang dikodekan sebagai string simbolis linier dengan panjang tetap. Meskipun panjangnya tetap, kromosom GEP dapat mengkode pohon ekspresi dengan berbagai bentuk dan ukuran. Menurut Ferreira (2006), GA dan GP sama-sama mengalami tradeoff antara kompleksitas fungsional dan kemudahan modifikasi genetik, sementara GEP tidak, karena adanya pemisahan genotipe/fenotipe, sebagaimana dijelaskan di bagian selanjutnya. Para peneliti dari berbagai disiplin ilmu telah memanfaatkan teknik GEP untuk memecahkan masalah teknik sipil.

4.4 ALGORITMA PEMROGRAMAN EKSPRESI GEN (GEP)

Struktur Kromosom GEP

GEP adalah algoritma genetika berbasis genotipe/fenotipe, di mana kromosom dan pohon ekspresi (ET) berfungsi sebagai genotipe dan fenotipe, masing-masing. Pemetaan dari ruang genotipe ke fenotipe disebut dekoding, dan sebaliknya disebut pengkodean. Dalam GEP, setiap kromosom terdiri dari satu atau lebih gen dengan panjang yang sama. Jumlah gen dipilih untuk setiap permasalahan. Setiap gen dapat direpresentasikan secara ringkas sebagai ekspresi-K, menggunakan bahasa Karva yang diciptakan oleh Ferreira khusus untuk membaca dan mengekspresikan informasi yang terkandung dalam kromosom GEP. Ekspresi-K diperoleh dengan membaca pohon ekspresi dari kiri ke kanan dan dari atas ke bawah, seperti membaca buku. Dengan adanya ekspresi-K, representasi ET yang sesuai ditentukan secara unik dengan cara yang mudah.

Ciri khas GEP adalah setiap gen terdiri dari kepala dan ekor. Kepala mengkodekan fungsi dan terminal, sedangkan ekor mengkodekan terminal. Panjang kepala telah ditentukan sebelumnya untuk setiap masalah, sedangkan panjang ekor (t) ditentukan menggunakan:

$$t = h \times (n - 1) + 1 \tag{4.1}$$

di mana h adalah panjang kepala dan n adalah aritas maksimum, yang didefinisikan sebagai jumlah argumen fungsi dengan argumen terbanyak. Panjang gen adalah jumlah panjang kepala dan ekor:


$$l = n \times h + 1 \tag{4.2}$$

ET yang sesuai dengan setiap gen dapat dikonstruksi dengan mempertimbangkan aturan-aturan berikut: (1) Baris pertama (posisi teratas) ET ditempati oleh posisi pertama gen, yang disebut akar; (2) Jumlah simpul di setiap baris ditentukan oleh jumlah argumen fungsi pada baris di atasnya; (3) Simpul di setiap baris diisi secara berurutan, membaca elemen-elemen yang tersisa dari ekspresi-K; (4) Proses selesai ketika baris yang tidak mengandung fungsi apa pun diperoleh.

Karena titik terminasi ET tidak selalu bertepatan dengan posisi terakhir gen, gen GEP seringkali mengandung daerah yang tidak muncul di ET. Jika lokasi e gen menandai titik terminasi ET, lokasi e + 1 hingga l membentuk daerah non-pengkodean gen. Keberadaan daerah non-pengkodean memberi kromosom GEP kemampuan untuk mengkode ET dengan berbagai bentuk dan ukuran, meskipun memiliki panjang yang tetap. Ketika lokasi pertama gen ditempati oleh terminal, ET terdiri dari satu simpul. Di sisi ekstrem yang lain, ketika semua elemen kepala adalah fungsi dengan n argumen, ET berisi l node, sehingga mencapai ukuran maksimum yang mungkin. Sebagai contoh, Gambar 4.1 menunjukkan kromosom yang terdiri dari dua gen dengan panjang kepala 5. Sel yang diarsir mewakili ekor.


Gen 1											Gen 2										
0	1	2	3	4	5	6	7	8	9	0	0	1	2	3	4	5	6	7	8	9	0
+	a	-	/	b	B	a	b	a	b	b	*	-	b	b	a	b	b	a	a	b	a

Gambar 4.1: Ekspresi K kromosom dua gen.



Gambar 4.2: Sub-ET yang dikode oleh dua gen (a) Gen 1, (b) Gen 2.

Gambar 4.2a dan 4.2b menunjukkan sub-ET yang dikodekan oleh Gen 1 dan Gen 2, masing-masing. Sub-ET dari Gen 1 setara dengan ekspresi matematika $a + (b/a - b)$, sedangkan sub-ET dari Gen 2 setara dengan $(b - a)b$. Perhatikan bahwa meskipun kedua gen memiliki panjang 11 karakter, sub-ET yang dikodekannya memiliki ukuran yang berbeda. Sub-ET dari Gen 1 memiliki 7 simpul, sedangkan sub-ET dari Gen 2 memiliki 5 simpul.



Gambar 4.3: ET yang dihasilkan dengan menghubungkan dua ET melalui penjumlahan.

Sub-ET dapat digabungkan menjadi satu ET menggunakan fungsi penghubung yang menerima lebih dari satu argumen. Ketika ET dari gen-gen tersebut merepresentasikan persamaan aljabar, fungsi penghubungnya adalah fungsi matematika seperti penjumlahan atau perkalian. Di sisi lain, ET yang merepresentasikan ekspresi Boolean dapat ditautkan menggunakan fungsi Boolean seperti AND atau OR. Gambar 4.3 menunjukkan ET yang diperoleh dengan menghubungkan ET yang ditunjukkan pada Gambar 4.2 melalui penjumlahan.

Fungsi Kebugaran

Langkah penting dalam semua algoritma evolusi konvensional adalah evaluasi setiap solusi kandidat menggunakan fungsi kebugaran yang telah ditentukan sebelumnya untuk mengukur tingkat pemenuhan tujuan optimasi. Fungsi kebugaran dapat didefinisikan sebagai pemetaan dari kromosom ke nilai skalar. Fungsi ini berkaitan erat dengan fungsi objektif yang

digunakan dalam optimasi matematis, dan dalam kasus optimasi tanpa kendala, kedua istilah tersebut sering kali dapat digunakan secara bergantian. Karena algoritma optimasi dipandu oleh skor kebugaran solusi kandidat, pemilihan fungsi kebugaran yang tepat sangat penting bagi keberhasilan setiap algoritma genetika.

Fungsi kebugaran yang baik harus memiliki definisi matematis yang jelas, dan nilai yang dihasilkannya harus mudah diinterpretasikan dalam konteks tujuan optimasi yang diinginkan. Secara tradisional, fungsi kebugaran dipilih sedemikian rupa sehingga menghasilkan nilai positif, dengan nilai yang lebih tinggi sesuai dengan solusi yang lebih baik. Pertimbangan penting lainnya dalam memilih fungsi kebugaran adalah implementasinya yang efisien. Karena fungsi kebugaran dievaluasi berkali-kali selama proses optimasi, komputasinya harus cukup cepat.

Dalam permasalahan regresi, di mana variabel dependen bersifat numerik, dan seringkali kontinu, kebugaran kromosom dapat dievaluasi berdasarkan ukuran kesalahan. Meskipun tujuannya adalah menemukan ekspresi matematika yang menghasilkan nilai yang mendekati nilai target untuk setiap kromosom dan setiap kasus kebugaran, penggunaan rentang seleksi yang terlalu sempit bermasalah karena memperlambat evolusi populasi, yang pada gilirannya dapat mencegah algoritma menemukan solusi yang baik. Penggunaan seleksi yang sangat luas juga bermasalah, karena dalam kasus ini, nilai kebugaran yang tinggi belum tentu sesuai dengan solusi yang baik. Untuk permasalahan regresi simbolik, fungsi kebugaran mengambil bentuk Persamaan (4.3) dan Persamaan (4.4), masing-masing, dengan menggunakan kesalahan absolut dan kesalahan relatif:

$$f_i = \sum_{j=1}^{C_t} (M - |C_{(i,j)} - T_j|) \quad (4.3)$$

$$f_i = \sum_{j=1}^{C_t} \left(M - \left| 100 \times \frac{C_{(i,j)} - T_j}{T_j} \right| \right) \quad (4.4)$$

di mana M adalah konstanta yang mewakili rentang seleksi, $C_{(i,j)}$ adalah nilai yang dikembalikan oleh kromosom individu i untuk kasus kebugaran j , dan T_j adalah nilai target untuk kasus kebugaran j , dan C_t adalah jumlah kasus kebugaran. Dalam kasus kecocokan sempurna, $C_{(i,j)}$ sama dengan nilai target T_j untuk semua kasus kebugaran, yang mengarah ke nilai kebugaran $f_i = M \times C_t$ menggunakan salah satu persamaan. Fungsi kebugaran dapat didefinisikan dengan banyak cara lain, menggunakan berbagai metrik kesamaan, seperti koefisien korelasi kuadrat atau kesalahan kuadrat rata-rata.

Dalam masalah klasifikasi, di mana variabel target kategoris atau nominal diprediksi, fungsi kebugaran dirancang dengan mempertimbangkan tingkat klasifikasi yang benar dan salah. Untuk masalah klasifikasi sederhana dengan dataset seimbang, jumlah contoh yang diklasifikasikan dengan benar dapat digunakan sebagai fungsi kebugaran. Pendekatan ini mungkin tidak bekerja dengan baik untuk masalah klasifikasi yang kompleks, terutama untuk

masalah yang melibatkan dataset yang tidak seimbang. Dalam kasus seperti itu, fungsi kebugaran yang efisien dapat dirancang menggunakan jumlah positif benar, negatif benar, positif salah, dan negatif salah, dengan memberikan bobot yang berbeda pada keempat jumlah ini. Pendekatan serupa dapat digunakan dalam permasalahan di mana variabel target merepresentasikan prediksi biner atau Boolean.

Operator Genetik

Operator genetik adalah fungsi yang beroperasi pada satu atau dua kromosom, yang berpotensi memodifikasi komposisi genetiknya. Operator genetik menentukan komposisi genetik keturunan dan membantu eksplorasi ruang pencarian yang efisien. Dalam bentuknya yang paling dasar, GEP menggunakan tiga jenis utama operator genetik: seleksi, persilangan, dan mutasi. Seleksi mengacu pada identifikasi individu yang cocok untuk menciptakan generasi berikutnya.

Alih-alih menggunakan algoritma greedy, di mana seleksi dilakukan hanya berdasarkan skor kebugaran, pendekatan probabilistik lebih disukai di mana skor kebugaran yang tinggi meningkatkan kemungkinan terpilih, tetapi tidak menjamkannya. Rekombinasi, juga disebut persilangan, mengacu pada penggabungan dua kromosom induk untuk menghasilkan dua keturunan. Dalam algoritma GEP, tiga jenis rekombinasi didefinisikan: rekombinasi satu titik, rekombinasi dua titik, dan rekombinasi gen. Dalam rekombinasi satu titik, dua kromosom induk dibelah pada titik yang sama, dan segmen di hilir titik ini dipertukarkan. Lokasi titik ini ditentukan secara acak.

Dalam rekombinasi dua titik, dua titik dipilih secara acak, dan kedua kromosom induk bertukar materi di antara kedua titik tersebut. Dalam rekombinasi gen, kedua kromosom induk bertukar seluruh gen. Mutasi mengacu pada perubahan acak pada kromosom untuk memperkenalkan dan mempertahankan keragaman dalam populasi. Mutasi menyediakan mekanisme yang memungkinkan populasi keluar dari optimum lokal, sehingga membantu eksplorasi ruang pencarian yang efisien. Berbeda dengan crossover, yang utamanya merupakan aksi lokal yang membantu eksploitasi subruang saat ini, mutasi dapat menghasilkan solusi di luar subruang saat ini. Sifat ini membantu algoritma mencegah terjebak dalam optimum lokal.

Selain operator-operator dasar ini, berbagai operator genetik yang mengubah arsitektur telah dikembangkan. Operator inversi bekerja dengan memilih segmen kepala gen secara acak dan membalik urutan karakter yang menempati segmen ini. Karena wilayah ekor tidak diubah selama operasi ini, ekor gen baru tidak memiliki fungsi apa pun, sehingga tidak ada risiko terciptanya gen yang salah secara sintaksis. Operasi genetik lainnya adalah transposisi. Dalam GEP, transposisi memiliki tiga bentuk berbeda. Yang pertama adalah transposisi Urutan Penyisipan (IS), yang mengacu pada fragmen pendek yang bertransposisi ke kepala gen, menghindari elemen pertama kepala, yang berkorespondensi dengan akar ET yang dikodekan oleh gen tersebut. Yang kedua adalah transposisi Urutan Penyisipan Akar (RIS), yang mengacu pada fragmen pendek yang dimulai dengan fungsi yang bertransposisi ke akar gen. Yang ketiga adalah transposisi gen yang mengacu pada total gen yang bertransposisi ke awal kromosom.

4.5 MODEL GEP UNTUK KUAT TEKAN HPC

Pada bagian ini, hubungan untuk kuat tekan HPC berdasarkan usia dan bahan campuran diturunkan. GeneXproTools (GeneXproTools. Versi 4.0) digunakan untuk pengembangan model GEP.

Basis Data

Model GEP dikembangkan menggunakan basis data Kuat Tekan Beton yang diperoleh dari Repositori Pembelajaran Mesin UCI (UC Irvine). Basis data tersebut berisi 1030 hasil uji kuat tekan HPC, yang mewakili berbagai proporsi campuran dan usia pengujian. Setiap observasi terdiri dari sembilan variabel: delapan variabel masukan dan kuat tekan sebagai variabel keluaran. Tabel 4.1 menunjukkan statistik deskriptif variabel masukan dan keluaran.

Tabel 4.1: Statistik deskriptif variabel.

	Semen (Kg/m ³)	Terak Tanur Tinggi (Kg/m ³)	Fly Ash (Kg/m ³)	Air (Kg/m ³)	Superplasticizer (Kg/m ³)	Agregat Kasar (Kg/m ³)	Agregat Halus (Kg/m ³)	Usia (Hari)	Kekuatan Tekanan (MPa)
Rata-rata	281.17	73.90	54.19	181.57	6.20	972.92	773.58	45.66	35.82
Standart Deviasi	104.51	86.28	64.00	21.36	5.97	77.75	80.18	63.17	16.71
Median	272.90	22.00	0.00	185.00	6.35	968.00	779.51	28.00	34.44
Mode	425.00	0.00	0.00	192.00	0.00	932.00	594.00	28.00	33.40
Minimal	102.00	0.00	0.00	121.75	0.00	801.00	594.00	1.00	2.33
Maksimal	540.00	359.40	200.10	247.00	32.20	1145.00	992.60	365.00	82.60

Basis data yang digunakan dibagi secara acak menjadi dataset pelatihan (80%) dan dataset uji (20%). Data pelatihan digunakan untuk menghasilkan model GEP. Data uji digunakan untuk mengevaluasi kinerja model.

Parameter dan Pengaturan yang Ditetapkan Pengguna

Ekspresi umum untuk kuat tekan (s) diberikan sebagai berikut:

$$s = f(d_0, d_1, d_2, d_3, d_4, d_5, d_6, d_7) \quad (4.5)$$

di mana $d_0, d_1, d_2, d_3, d_4, d_5, d_6$, dan d_7 masing-masing mewakili umur pengujian (hari), terak tanur tinggi (kg/m³), semen (kg/m³), agregat kasar (kg/m³), abu terbang (kg/m³), agregat halus (kg/m³), superplasticizer (kg/m³), dan air (kg/m³). Diasumsikan bahwa kromosom GEP terdiri dari tiga gen dengan panjang kepala dua belas. Operator penjumlahan dipilih sebagai fungsi penghubung.

Set fungsi terdiri dari delapan operasi berikut: penjumlahan, pengurangan, perkalian, pembagian, pangkat, akar kuadrat, eksponensial, dan logaritma natural. Set terminal terdiri dari tujuh prediktor (d_0 hingga d_7), ditambah dua konstanta numerik per gen. Kebugaran

individu dievaluasi berdasarkan root-mean-squared-error (RMSE), menggunakan fungsi berikut:

$$f_i = \frac{1000}{1 + RMSE_i} \quad (4.6)$$

Dimana

$$RMSE_i = \frac{1}{C_t} \sum_{j=1}^{C_t} (C_{(i,j)} - T_j)^2 \quad (4.7)$$

C_t adalah jumlah kasus kebugaran, $C_{(i,j)}$ adalah nilai yang dikembalikan oleh kromosom individu i untuk kasus kebugaran j , dan T_j adalah nilai target untuk kasus kebugaran j . Karena GEP bertujuan untuk memaksimalkan kebugaran, RMSE sendiri bukanlah fungsi kebugaran yang valid. Untuk mendapatkan fungsi kebugaran yang valid, di mana RMSE yang lebih rendah berkorespondensi dengan skor kebugaran yang lebih tinggi, RMSE digunakan dalam penyebut fungsi kebugaran. Skalar 1 ditambahkan ke RMSE untuk mencegah pembagian dengan nol. Akhirnya, 1000 yang digunakan dalam pembilang menunjukkan nilai kebugaran maksimum yang mungkin. Perhatikan bahwa $f_i = 1000$ jika kromosom i mereproduksi nilai target dengan sempurna untuk semua kasus kebugaran.

Salah satu parameter terpenting yang harus dipilih oleh pengguna adalah ukuran populasi. Ketika ukuran populasi kecil, algoritma mungkin konvergen ke solusi yang buruk. Di sisi lain, populasi yang besar mungkin memerlukan waktu pencarian yang berlebihan. Populasi 10–160 individu disarankan untuk aplikasi umum. Dalam bab ini, ukuran populasi ditetapkan sebesar 100. Pemilihan parameter kontrol lainnya ditentukan secara coba-coba, dengan mempertimbangkan temuan yang dilaporkan dalam studi serupa. Tabel 4.2 menunjukkan parameter kontrol yang digunakan dalam eksekusi algoritma GEP. Proses ini diulang hingga solusi mencapai plateau, dan tidak ada peningkatan signifikan yang dicapai pada skor kebugaran rata-rata kromosom.

Tabel 4.2: Parameter kontrol yang digunakan dalam algoritma GEP.

Parameter	Nilai
Ukuran populasi	100
Jumlah gen	3
Panjang kepala	12
Fungsi menghubungkan	Tambahan
Tingkat mutasi	0,044
Tingkat inversi	0,1
Tingkat transposisi IS	0,1
Tingkat transposisi RIS	0,1
Tingkat transposisi gen	0,1
Tingkat rekombinasi satu titik	0,3

Tingkat rekombinasi dua titik	0,3
Tingkat rekombinasi gen	0,1

Hasil

Persamaan untuk kuat tekan HPC yang diperoleh menggunakan algoritma GEP adalah:

$$S = s_1 + s_2 + s_3 \tag{4.8}$$


di mana s adalah kekuatan tekan, dan s_1, s_2 dan s_3 adalah ekspresi yang diwakili oleh tiga gen kromosom terkuat yang dipilih oleh algoritma GEP, yang didefinisikan sebagai berikut:

$$s_1 = d_2 \times \ln \left[\sqrt{\frac{d_0}{\left(\frac{-0.109d_3 - 2.77 + d_7}{-0.361d_7 + d_2}\right)}} \right]$$

$$s_2 = \left[4.58(d_0 + \sqrt{d_6} - 2.94) \left(\frac{d_1^2}{d_7}\right) \right]^{0.25} + d_5^{0.1}$$

$$s_3 = -9.91 + \sqrt{(d_4 + d_6)^{0.25} \left(\frac{d_0(d_2 - d_6)}{d_0 + d_7}\right)}$$

Gambar 4.4 membandingkan prediksi kekuatan tekan model GEP dengan nilai yang diukur secara eksperimen yang diperoleh menggunakan set pelatihan dan pengujian.



Gambar 4.4: Kuat tekan HPC terukur versus kuat tekan HPC terprediksi menggunakan model GEP: (a) set pelatihan dan (b) set uji.

Tabel 4.3 menunjukkan metrik kinerja model berbasis GEP yang dihasilkan untuk kuat tekan, yang direpresentasikan oleh Persamaan (4.8). Dalam tabel ini, R menunjukkan koefisien korelasi, RMSE adalah galat akar kuadrat rata-rata, dan MAE adalah galat absolut rata-rata.

Tabel 4.3: Metrik kinerja model GEP.

	R	R^2	RMSE	MAE
Training	0.9493	0.9012	4.8182	3.9996
Test	0.9506	0.9036	4.7499	4.0844

Menurut Smith (1986), model regresi dengan koefisien korelasi $|R| > 0,8$ menyiratkan kinerja yang baik. Meskipun merupakan indikator yang baik untuk tingkat linearitas, koefisien korelasi antara nilai prediksi dan target bukanlah indikator yang andal untuk akurasi model. Bahkan, ketika salah satu atau kedua variabel mengalami transformasi linear, di mana semua nilai variabel dimodifikasi dengan menambahkan konstanta dan/atau mengalikannya dengan konstanta, koefisien korelasinya tetap sama.

Oleh karena itu, metrik tambahan diperlukan untuk menilai kinerja setiap model regresi. Rata-rata galat absolut (MAE) dan RMSE merupakan metrik yang berguna dalam hal ini. Nilai MAE dan RMSE yang rendah, seperti yang ditunjukkan pada Tabel 4.3, menunjukkan kemampuan model untuk menghasilkan prediksi yang mendekati nilai terukur. Lebih lanjut, kesamaan nilai yang diperoleh untuk metrik ini pada dataset pelatihan dan uji menunjukkan kinerja generalisasi yang baik.

4.6 KESIMPULAN

Teknik regresi banyak digunakan dalam berbagai disiplin ilmu untuk menggambarkan hubungan antara variabel target dan satu atau lebih variabel prediktor, berdasarkan serangkaian observasi empiris. Ekspresi matematika yang dihasilkan menghasilkan prediksi variabel target untuk berbagai nilai variabel input, sehingga mengurangi kebutuhan pengumpulan data dunia nyata untuk berbagai pengaturan variabel prediktor. Penggunaan model regresi untuk memprediksi berbagai sifat mekanik beton mengurangi kebutuhan akan uji laboratorium yang melelahkan, memakan waktu, dan mahal.

Penelitian ini menggunakan GEP, sebuah varian dari pemrograman genetik, untuk mengembangkan model regresi baru untuk kuat tekan HPC menggunakan basis data 1030 hasil uji tekan HPC. Performa prediksi model dievaluasi menggunakan set uji yang menggunakan ukuran korelasi dan galat, dan hasilnya memuaskan. Kesamaan nilai performa pada data pelatihan dan uji merupakan tanda bahwa model tidak overfit jika observasi diasumsikan independen. Berbeda dengan ANN, GEP adalah metode bebas gradien yang mampu menangani masalah optimasi multi-objektif yang kompleks, tanpa terjebak dalam minimum lokal.

Ada dua keterbatasan dari pendekatan yang diusulkan. Yang pertama terkait dengan basis data yang digunakan dalam penelitian ini, yang telah digunakan oleh banyak peneliti lain. Secara tegas, observasi yang tercantum dalam basis data tidak independen. Misalnya, basis data berisi beberapa hasil uji dari campuran yang sama, yang diuji pada waktu yang berbeda (7 hari, 28 hari, dst.). Kurangnya independensi observasi berarti bahwa model yang dihasilkan tidak kebal terhadap overfitting, meskipun metrik kinerja yang dihitung untuk set pelatihan dan pengujian serupa. Yang kedua berkaitan dengan interpretabilitas model GEP. Salah satu

keunggulan GEP dibandingkan pendekatan pembelajaran mesin adalah interpretabilitas model yang dihasilkan, berbeda dengan pendekatan kotak hitam ANN.

Meskipun hal ini mungkin berlaku untuk model sederhana yang terdiri dari satu atau dua prediktor, ekspresi matematika yang dihasilkan oleh GEP menjadi rumit seiring bertambahnya jumlah prediktor. Lebih lanjut, karena pengguna diharuskan untuk menentukan terlebih dahulu himpunan fungsi, himpunan terminal, jumlah dan panjang gen, serta fungsi penghubung, bentuk matematika dari ekspresi yang dihasilkan sebagian telah ditentukan sebelumnya oleh pengguna. Oleh karena itu, meskipun GEP tampaknya menghasilkan prediksi yang akurat, mungkin sulit untuk memahami hubungan yang kompleks.

BAB 5

BASIS DATA PENILAIAN STRUKTUR DAN ANALISIS KOMPLEKS

5.1 PENDAHULUAN

Baik struktur beton maupun baja terpapar degradasi internal maupun eksternal serta agen-agen perusak selama masa pakainya. Misalnya, struktur beton rentan terhadap reaksi alkali-silika, korosi tulangan, kristalisasi garam, serangan sulfat, siklus beku-cair, pembentukan ettringite yang tertunda, dan sebagainya. Jenis degradasi dan kerusakan ini membahayakan daya tahan dan kemudahan servis struktur. Retakan terbentuk karena agen-agen yang disebutkan di atas, dan perluasan serta koalesensi retakan yang ada dapat merusak integritas struktur beton. Struktur baja juga terpapar korosi dan retak getas. Merekonstruksi infrastruktur yang rusak sangat mahal dan membutuhkan sumber daya serta energi yang besar.

Oleh karena itu, inspeksi dan pemantauan struktural menjadi semakin penting dalam beberapa tahun terakhir. Pemantauan kesehatan struktural infrastruktur penting dapat menghasilkan perpanjangan masa pakai struktural yang wajar. Emisi akustik (AE) merupakan salah satu metode pemantauan kesehatan struktur. AE merupakan fenomena di mana suatu material memancarkan gelombang tegangan akibat pelepasan energi secara tiba-tiba, seperti retak. Sensor piezoelektrik digunakan untuk menangkap gelombang mekanis ini dan mengubahnya menjadi sinyal digital. Sinyal tersebut memiliki informasi berharga tentang pembentukan retak dan kondisi internal material tempat retakan terbentuk. Banyak penelitian telah berfokus pada penggunaan AE untuk melokalisasi pembentukan retak, menilai kerusakan, dan memantau kesehatan struktur.

Data emisi akustik biasanya mencakup fitur parametrik yang diekstraksi dari sinyal. Mengelola, menganalisis, memahami, dan menginterpretasikan data dapat menjadi tantangan karena kompleksitas data yang berkaitan dengan detail struktural, durasi pemantauan, dan evolusi temporal sifat akustik material. Saat ini, terdapat beberapa metode berbasis data yang tersedia untuk mengatasi tantangan terkait data dan prediksi pola data, termasuk metode berbasis konsep statistik dan algoritma pembelajaran mesin.

5.2 SUMBER GELOMBANG AE PADA BERBAGAI STRUKTUR

Gelombang AE dipancarkan karena mekanisme yang berbeda-beda dalam struktur. Pada bagian berikut, beberapa mekanisme degradasi yang menyebabkan pembentukan gelombang AE akan dibahas.

Retak Korosi Tegangan


Retak dapat dimulai dan menyebar pada struktur baja dalam kondisi korosif. Retak pada struktur baja disebut sebagai retak korosi tegangan (SCC) ketika disebabkan oleh pemberian tegangan dalam kondisi korosif. Paduan baja yang digunakan dalam struktur umumnya dianggap ulet atau fleksibel. Ketika paduan baja terpapar suhu tinggi, mereka dapat menjadi

sensitif terhadap korosi. Produk korosif yang terbentuk dalam baja lebih getas daripada baja ulet aslinya dan rentan terhadap retak.

Oleh karena itu, dengan adanya tegangan, retak dapat terjadi. Proses degradasi ini juga dapat diamati pada paduan baja tahan karat austenitik ketika spesies kimia baja berubah karena paparan suhu tinggi (misalnya, pengelasan). Karbon dalam material berikatan dengan kromium dan membentuk karbida di batas butir, yang mengurangi konsentrasi kromium di dekat batas butir dan membuat baja lebih rentan terhadap SCC intergranular. Gambar 5.1 menunjukkan bagaimana perlakuan panas memengaruhi struktur kristal baja tahan karat 304 L.

Salah satu risiko potensial SCC dalam struktur terkait dengan sistem penyimpanan tong kering (DCSS). DCSS adalah sistem pembuangan limbah nuklir sementara yang telah digunakan sejak tahun 1970-an. Strukturnya berupa tabung baja tahan karat (silinder vertikal) yang membungkus bahan bakar nuklir bekas dan limbah tingkat tinggi. DCSS ditutupi oleh tutup baja, yang dilas ke tabung. Pengelasan pada wadah penyimpanan menyebabkan material austenitik menjadi sensitif dan lebih rentan terhadap SCC. Retakan mikro diperkirakan akan terbentuk di daerah las karena paparan DCSS terhadap lingkungan. Retakan mikro akan melebar, meluas, dan menjadi retakan makro. Retakan tersebut membahayakan kemudahan servis DCSS dan pada akhirnya dapat menimbulkan kekhawatiran kebocoran radiasi ke lingkungan.

Memeriksa retakan pada tabung baja secara visual merupakan tantangan tersendiri. Selain itu, struktur penyimpanan ini biasanya memiliki akses terbatas, sehingga inspeksi rutin tidak dapat dilakukan. Teknologi AE dapat digunakan dalam kasus ini, memanfaatkan sensitivitas tinggi sensor AE serta sifat non-destruktif dari metode ini. Retakan mikro terbentuk di area las tabung. Kemudian, gelombang tegangan dihasilkan dan merambat melalui material hingga mencapai sensor AE. Sensor dalam jumlah minimal dapat dipasang di bagian bawah tabung atau di alasnya.



(a) Sensitisasi setelah 2 jam

(b) Sensitisasi setelah 14 jam

Gambar 5.1: Evolusi struktur kristal baja selama perlakuan panas.

Retak Akibat Reaksi Alkali-Silika

Banyak struktur beton seperti bendungan, jembatan, struktur nuklir, dan struktur hidrolik terpapar reaksi alkali-silika (ASR). ASR adalah reaksi kimia yang terjadi antara alkali hidroksida dan mineral silika pada beberapa agregat yang digunakan dalam struktur beton. Komponen reaksi tersedia dalam struktur beton. Produk reaksi berupa gel higroskopis, yang terbentuk di sekitar dan/atau di dalam agregat.

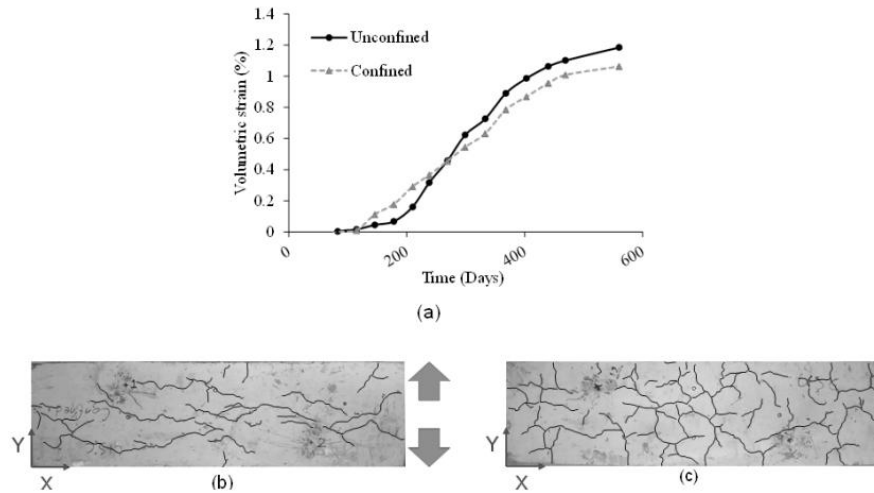
Gel ini cenderung menyerap kelembapan dari pori-pori beton atau retakan dini, lalu mengembang. Volume gel lebih besar daripada komponen awal reaksi. Oleh karena itu, gel memberikan tekanan pada komponen beton di sekitarnya, seperti agregat, pasta semen, dan zona transisi antarmuka. Jika gel menemukan jalur (retakan atau rongga) untuk mengalir, tekanannya akan turun. Jika tidak, tekanan akan terakumulasi dan melampaui kekuatan patah material yang menyebabkan retakan mikro dan perluasan retakan pada beton. ASR dalam struktur beton dapat disertai oleh agen degradasi lain seperti siklus beku-cair, penetrasi klorida dalam beton dan korosi baja, serta pembentukan ettringite yang tertunda, yang mempercepat degradasi.

Laju reaksi bergantung pada beberapa faktor seperti reaktivitas agregat, kandungan ion natrium dan kalium dalam semen, ketersediaan alkali hidroksida dalam larutan pori, kelembapan tinggi (lebih dari 80%), suhu tinggi, dan pengurungan dari berbagai arah. Retak mikro ASR di dalam struktur beton menyatu dan melebar melalui proses ASR. Reaksi dimulai dengan laju yang lebih rendah, kemudian laju meningkat diikuti oleh penurunan. Laju perkembangan ASR dapat diamati dengan mengukur ekspansi beton. Regangan ekspansi memiliki tren yang serupa dengan reaksi. Gambar 5.2a menunjukkan regangan volumetrik blok beton yang terpapar suhu dan kelembapan tinggi selama 560 hari.

Faktor penting lainnya dalam retak akibat ASR adalah pengekangan internal atau eksternal. Struktur beton dapat terkekang secara internal terhadap arah tertentu karena adanya tulangan yang tegak lurus terhadap arah tersebut. Lebih lanjut, pengekangan tersebut dapat dipaksakan secara eksternal pada suatu struktur. Salah satu contohnya adalah struktur kaku, yang dapat menahan struktur di sebelahnya dari ekspansi ASR ke arah tertentu.

Pengekangan dalam satu arah tidak serta merta mencegah beton retak. Menurut Gambar 5.2b, blok beton yang terkekang sebagian besar retak dalam satu arah, sementara retak pada blok yang tidak terkekang terdistribusi lebih acak (Gambar 5.2c). Arah bukaan retak pada spesimen terkekang tegak lurus terhadap bidang dengan tulangan seperti ditunjukkan pada Gambar 5.2b.

Gelombang tegangan dihasilkan akibat pembentukan retak ASR pada struktur beton dan direkam sebagai sinyal digital. Fitur sinyal dapat dipengaruhi oleh mekanisme fraktur retak aktif pada berbagai tahap ASR, potensi evolusi sifat akustik internal beton selama ASR, kopling sensor, geometri struktur, dan komponen beton (tulangan, ukuran dan jenis agregat, rasio rongga).




Gambar 5.2: (a) Regangan volumetrik blok beton akibat ASR yang dipercepat; (b) retak pada spesimen terkekang; (c) retak pada spesimen tidak terkekang.

Pembebanan dan Dampak

Sinyal AE dapat dihasilkan oleh pembentukan retak yang disebabkan oleh pembebanan eksternal atau dampak. Dalam ilmu material, AE dapat digunakan untuk menyelidiki berbagai mekanisme retak dan mekanika fraktur. Mekanisme retak dapat diidentifikasi dengan analisis momen tensor atau menggunakan metode pembelajaran mesin. Uji beban juga digunakan sebagai prosedur untuk mengevaluasi kondisi struktur di bawah beban layanan. Di Amerika Serikat, uji beban dilakukan menggunakan muatan truk standar untuk menilai kondisi jembatan dan melepas tiang beban. Salah satu metode untuk mengevaluasi komponen superstruktur jembatan adalah dengan menghitung faktor distribusi perpindahan antar pelat menggunakan sensor perpindahan dan regangan selama uji beban. Namun, pengujian beban konvensional membutuhkan waktu dan biaya yang besar.

Komponen superstruktur beton jembatan (dek jembatan atau girder) memiliki retakan dan cacat akibat kondisi beton yang belum sempurna atau faktor degradasi. Retakan yang ada pada dek jembatan atau girder terbuka atau melebar saat truk melewati jembatan, menghasilkan gelombang tegangan. Gelombang ini dapat ditangkap oleh sensor AE yang ditempatkan pada komponen jembatan. Keunggulan AE dibandingkan pengukur tegangan atau sensor perpindahan adalah sensitivitasnya yang lebih tinggi, yang dapat membantu evaluasi jembatan. Pemantauan AE tidak terbatas pada infrastruktur teknik sipil, tetapi juga dapat digunakan pada struktur kedirgantaraan. Gelombang AE dihasilkan oleh dampak puing atau hujan es yang menghantam komponen pesawat, seperti lift, selama penerbangan. Dampaknya dapat menyebabkan kerusakan ringan, yang disebut kerusakan benturan yang hampir tidak terlihat (BVID), pada permukaan yang diproduksi dengan material komposit serat. Lokasi dan tingkat kerusakan berkorelasi dengan evolusi fitur sinyal AE. Gambar 5.3 mengilustrasikan dampak pada elevator pesawat yang digunakan untuk mengumpulkan data AE untuk algoritma pembelajaran mesin.



Gambar 5.3: Dampak pada elevator pesawat untuk pengumpulan data

5.3 PENDEKATAN ANALISIS DATA

Teknik berbasis data bertujuan untuk menemukan fitur dan struktur inheren dari fenomena kompleks dengan mengevaluasi data dari berbagai aspek. Teknik ini didasarkan pada hubungan matematis yang diturunkan dari data eksperimen dan dapat digunakan untuk deteksi dan prediksi kerusakan ketika model fisik tidak tersedia, tetapi perilaku kerusakan historis dapat diakses. Meskipun metode berbasis data efisien untuk dataset yang bising dan perilaku kompleks, metode ini juga mungkin membutuhkan komputasi yang mahal. Namun, kelemahan tersebut semakin berkurang berkat kemajuan progresif dalam perangkat keras komputasi dan komputer kluster.

Dalam metode berbasis fisika, ketersediaan model fisik dan kondisi pembebanan sangat penting. Setiap model harus divalidasi dan parameternya ditentukan sebelum penerapan, yang tidak selalu memungkinkan dan mudah. Kecerdasan komputasi, pembelajaran mesin, dan regresi adalah tiga contoh metode berbasis data. Pengenalan pola dapat dikategorikan dalam bidang pembelajaran mesin, yang berfokus pada penemuan keteraturan dalam suatu dataset dengan menggunakan algoritma komputer.

Ada dua kategori utama yang terkait dengan metode ini: pengenalan pola tanpa pengawasan dan terawasi. Pengenalan pola tanpa pengawasan digunakan untuk menemukan dan mengelompokkan data yang tidak berlabel ketika tidak ada pola yang telah ditentukan sebelumnya. Di sisi lain, pengenalan pola terawasi digunakan ketika dataset berlabel yang besar dapat diakses untuk pelatihan. Selanjutnya, algoritma yang telah dilatih dapat digunakan untuk mengklasifikasikan data baru.

Persiapan Data sebelum Analisis

Meskipun sensitivitas AE yang tinggi digunakan untuk deteksi dini kerusakan atau deteriorasi, keunggulan ini dapat menyebabkan pengumpulan data dalam jumlah besar selama akuisisi, yang membawa lebih banyak tantangan bagi manajemen dan analisis data. Oleh karena itu, pendekatan yang berbeda perlu diambil untuk mengenali data yang lebih berharga (data esensial) dalam data mentah. Data AE yang asing dapat dikumpulkan karena beberapa alasan dalam sistem akuisisi data. Derau latar belakang, derau listrik, derau mekanis,

data pantulan batas, dan data lingkungan yang tidak relevan merupakan beberapa data tidak asli yang berpotensi terekam selama pemantauan struktural.

Derau latar belakang biasanya ditangani dengan menetapkan ambang batas yang sesuai dalam sistem sebelum menjalankan pengujian. Langkah pertama sebelum menggunakan sistem AE adalah menjalankan uji derau latar belakang selama beberapa jam untuk memastikan lingkungan pengujian tidak terkontaminasi secara akustik. Dengan menggunakan informasi ini, ambang batas amplitudo yang sesuai untuk sistem dapat ditetapkan. Lebih lanjut, direkomendasikan agar sensor AE dipasang pada komponen dalam kondisi kontrol selama pengujian. Kebisingan mekanis dapat dihasilkan oleh gesekan antara komponen struktural selama pembebanan struktur atau antara struktur dan instrumen pembebanan. Solusi untuk mengurangi kebisingan mekanis adalah dengan mengisolasi instrumentasi pembebanan sebisa mungkin dari struktur dengan menggunakan material dengan impedansi akustik minimal, seperti bantalan neoprena, dan/atau sensor pelindung di sekitar komponen dengan potensi gesekan.


Derau listrik biasanya muncul pada komponen-komponen listrik seperti sambungan, kabel, saluran, atau sensor yang rusak. Penetrasi air pada sambungan juga merupakan salah satu penyebab derau listrik yang mungkin terjadi selama pemantauan jangka panjang struktur yang terpapar presipitasi lingkungan atau kondisi kelembapan tinggi. Untungnya, derau listrik dapat dikenali dengan jelas dari kumpulan data asli (Gambar 5.4). Derau listrik memiliki frekuensi rata-rata dan frekuensi puncak yang rendah dan dapat dihilangkan dengan menerapkan filter berbasis frekuensi. Tingkat hit untuk derau listrik tinggi, yang dapat menyebabkan masalah akuisisi dan buffering. Oleh karena itu, disarankan untuk memeriksa komponen listrik dan melindunginya dari air dengan menggunakan tabung susut.

Gelombang tegangan dipantulkan ketika mencapai media dengan impedansi atau batas struktur yang berbeda. Dalam uji spesimen skala kecil, menerima sejumlah besar pantulan dapat membingungkan dalam hal pemrosesan data. Metode sederhana untuk menyaring pantulan adalah menggunakan filter front-end. Hal ini biasanya diatur dalam sistem akuisisi data dengan menentukan pengaturan waktu seperti *Hit Definition Time* (HDT), *Peak Definition Time* (PDT), dan *Hit Lockout Time* (HLT). HLT adalah parameter yang secara langsung berkaitan dengan penghilangan tailing atau refleksi sinyal. HLT mengacu pada waktu di akhir sinyal di mana setiap perlintasan ambang batas diabaikan. Jumlah data tailing setelah suatu kejadian dapat disesuaikan menggunakan HLT.

Data mentah AE harus melalui beberapa filter agar bermanfaat untuk analisis data dan prosedur penilaian kerusakan. Salah satu metode penyaringan yang paling tradisional adalah filter Swansong II. Dalam metode ini, distribusi logaritma (durasi) versus amplitudo (dalam desibel (dbAE)) atau logaritma (waktu naik) versus amplitudo (dalam dbAE) digunakan untuk menentukan data yang tidak asli. Data AE asli dengan amplitudo rendah umumnya memiliki durasi rendah, dan data dengan amplitudo tinggi umumnya memiliki durasi tinggi. Data lainnya, yang tidak mengikuti aturan yang dinyatakan, disebut sebagai data tidak asli dan dihapus.

Dalam metode ini, batas penyaringan ditentukan dengan mengamati bentuk gelombang AE satu per satu dalam interval amplitudo yang berbeda. Oleh karena itu, ini memakan waktu dan tidak konsisten. Kerugian yang terakhir berarti bahwa metode penyaringan tergantung pada pengalaman dan preferensi, yaitu, data yang disaring oleh dua orang mungkin berbeda. Dengan demikian, penelitian telah dilakukan dengan menggunakan metode statistik dan pemrosesan sinyal untuk penyaringan data, Transformasi wavelet kontinu untuk mengenali data asli dari data yang berisik. Meskipun menggunakan metode yang berbeda untuk penyaringan, akurasi, dan kinerja dalam aplikasi yang berbeda masih dipertanyakan dan tampaknya filter Swansong II tetap menjadi salah satu metode yang paling dapat diandalkan untuk penyaringan AE.

Namun, seperti yang disebutkan, metode ini memakan waktu dan menantang untuk pemantauan jangka panjang dan AE tingkat rendah, di mana data yang diperoleh mungkin sebesar seratus gigabyte atau beberapa terabita. Untuk kasus ini, memasang beberapa sensor pada suatu struktur dalam rentang jarak sensitivitas sensor dapat bermanfaat untuk penyaringan cepat. Sebagai contoh, sebuah skrip telah dikembangkan untuk menyaring data AE berdasarkan definisi peristiwa.



Gambar 5.4: Perbandingan antara (a) data AE asli; dan (b) noise sambungan listrik.

Dalam kode tersebut, hit yang didaftarkan oleh sejumlah sensor tertentu dalam perbedaan waktu tertentu dikenali dan disimpan sebagai set data asli. Jumlah sensor bergantung pada jumlah locator yang digunakan dalam pengujian dan cakupan lokasi sumber proyek. Bidang dua dimensi dan ruang tiga dimensi masing-masing memerlukan setidaknya tiga dan empat sensor untuk pelokalan sumber menggunakan triangulasi. Metode penyaringan ini terbukti lebih cepat dan lebih konsisten daripada metode tradisional. Algoritmenya dapat diterapkan baik untuk data parametrik maupun bentuk gelombang.

Pada akhirnya, metode penyaringan yang telah disebutkan sebelumnya efisien hingga batas tertentu, tetapi tidak satu pun dapat menyaring semua data yang asing; oleh karena itu, inspeksi visual acak terhadap data yang disaring disarankan untuk memeriksa efisiensi metode penyaringan dan menghilangkan sisa data potensial yang tidak asli.

Setelah penyaringan, data AE harus diorganisasikan dan disiapkan untuk tujuan analisis. Misalnya, waktu yang dikaitkan dengan data dimodifikasi untuk merepresentasikan

pemantauan waktu nyata (real-time monitoring), dan data biasanya diorganisasikan berdasarkan waktu.

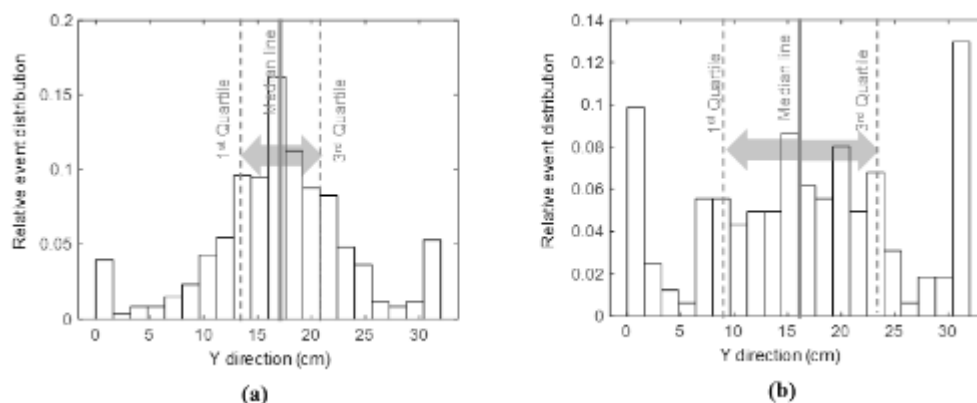
Analisis dan Distribusi Statistik

Bentuk gelombang AE merupakan sinyal non-stasioner. Oleh karena itu, berbagai metode statistik dan pemrosesan sinyal dapat digunakan untuk menganalisis data dan memperoleh informasi penting dari data yang kompleks. Outlier dalam fitur sinyal dapat diidentifikasi menggunakan metode statistik. Dalam statistik, outlier didefinisikan sebagai observasi dengan deviasi besar dari observasi lain. Outlier dalam suatu dataset dapat mengakibatkan kebingungan dan kesalahan dalam beberapa teknik berbasis data.

Misalnya, metode k-means diperkirakan akan salah mengklasifikasikan suatu dataset yang mengandung outlier. Oleh karena itu, dalam beberapa teknik berbasis data, identifikasi dan penghapusan outlier dari data sebelum melakukan analisis apa pun merupakan hal yang penting. Salah satu metode statistik yang paling sederhana adalah data end-trimming. Dalam metode ini, persentase (yaitu, 5% atau 10%) dari data tertinggi dan terendah dianggap sebagai data outlier dan dihapus dari kumpulan data.

Metode statistik umum lainnya adalah menggunakan plot kotak dan kumis. Dengan menghitung median, kuartil bawah, dan kuartil atas, sebuah boxplot dapat digambar untuk suatu kumpulan data. Kemudian, pagar dalam dan pagar luar ditentukan menggunakan kuartil dan rentang interkuartil. Terakhir, outlier ringan dan ekstrem diidentifikasi dengan mengamati data di pagar dalam dan luar.

Menghasilkan distribusi statistik dari data AE dapat membantu analisis fitur AE. Misalnya, kejadian distribusi di sepanjang dimensi tertentu dapat mewakili distribusi cracking. Pada Gambar 5.5, median kejadian, kuartil pertama, dan kuartil ketiga ditampilkan. Garis median memisahkan 50% data terendah dan 50% data tertinggi, dan kuartil pertama dan ketiga memisahkan 25% data terendah dari 75% data tertinggi, dan 25% data tertinggi dari 75% data terendah. Sumbu vertikal pada Gambar 5.5 adalah frekuensi relatif kejadian. Misalnya, pada Gambar 5.5a, nilai untuk bin pertama dari kiri kira-kira sama dengan 0,04, yang berarti hanya 4% data yang berukuran antara 0 hingga 1,6 cm. Dengan kata lain, probabilitas kejadian antara 0 hingga 1,6 cm adalah 4%. Distribusi untuk spesimen yang terkurung sama sekali berbeda dengan spesimen yang tidak terkurung.



Gambar 5.5: Distribusi kejadian relatif untuk spesimen beton yang terpapar kerusakan ASR, (a) Spesimen terkekang; (b) spesimen tidak terkekang.

Aplikasi lain dari metode statistik adalah penggunaan histogram frekuensi relatif sinyal untuk menghitung entropi Shannon, yang akan dijelaskan di bagian selanjutnya. Persamaan Gutenberg-Richter merupakan dasar untuk analisis nilai- b , yang digunakan dalam seismologi dan analisis risiko untuk menentukan hubungan antara frekuensi kejadian dan magnitudo kejadian. Versi modifikasi dari metode ini telah digunakan untuk data AE sebagai indeks kerusakan. Hubungan antara amplitudo AE (dalam dBAE) dan jumlah sinyal AE dengan amplitudo lebih besar dari A (amplitudo sinyal) disajikan sebagai berikut:

$$\log N = a - b\left(\frac{A}{20}\right) \quad (5.1)$$

Regresi linier dapat digunakan untuk menaksir a dan b karena hubungan antar $\log N$ dan A mendekati linier. Dua pendekatan direkomendasikan untuk menghitung nilai- b , nilai- b inkremental dan nilai- b global. Dalam metode pertama, seluruh data dipisahkan menurut interval dan nilai- b dihitung untuk data dalam setiap interval. Dalam nilai- b global, nilai- b dihitung untuk setiap waktu, dengan mempertimbangkan data AE yang terjadi sebelum waktu tersebut.

Selain nilai- b , koefisien determinasi (nilai R^2) dapat dihitung untuk mengidentifikasi deviasi data dari hubungan linier. Parameter ini dapat digunakan sebagai kriteria identifikasi kerusakan. Sinyal AE dipancarkan dengan laju yang lebih tinggi dan energi atau amplitudo yang lebih besar ketika kerusakan parah atau retak terjadi pada suatu struktur. Sinyal AE dengan amplitudo yang lebih tinggi menyebabkan data AE menyimpang dari hubungan nilai- b sehingga menurunkan koefisien determinasi untuk sistem. Nilai R^2 dihitung dari persamaan berikut:

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5.2)$$

di mana \hat{y} adalah nilai estimasi $\log N$ untuk titik ke- i dengan menggunakan garis yang difitting dan y adalah nilai riil $\log N$ untuk titik ke- i . \bar{y} adalah nilai rata-rata $\log N$. Indeks n menunjukkan data terakhir yang diinginkan untuk menghitung nilai- b .

Metode Pemrosesan Sinyal

Beberapa fitur dan informasi penting tertanam dalam sinyal AE. Dengan menggunakan metode pemrosesan sinyal, informasi inheren dapat diekstraksi dan digunakan untuk penilaian temporal fitur.

Transformasi Fourier Cepat

Transformasi Fourier mentransfer sinyal deret waktu ke isyarat domain frekuensi dengan mengonvolusi pesan digital tersebut dengan sinyal sinusoidal $e^{\frac{j2\pi kn}{N}}$ dengan frekuensi yang berbeda. Persamaan berikut merepresentasikan formulasi untuk transformasi Fourier:

$$X_k = \sum_{n=0}^{N-1} x_n e^{\frac{j2\pi kn}{N}} \quad (5.3)$$

dengan N adalah jumlah sampel, x_n adalah sinyal dalam domain waktu, dan X_k adalah koefisien transformasi Fourier untuk frekuensi ke- k .

Analisis Wavelet Kontinu

Transformasi wavelet (WT) digunakan untuk menyajikan distribusi energi sinyal dalam domain waktu-frekuensi. Berbeda dengan transformasi Fourier berjendela (WFT), WT menyajikan data dalam resolusi waktu tinggi untuk komponen frekuensi tinggi dan resolusi frekuensi tinggi untuk komponen frekuensi rendah. *CWT* didefinisikan menurut persamaan berikut:

$$CWT(a, b) = \int S(t) * |a|^{-0.5\psi} \left(\frac{t-b}{a} \right) dt \quad (5.4)$$

di mana a dan b masing-masing adalah parameter skala dan pergeseran. Parameter skala mengontrol kekompakan atau ekstensi sinyal (frekuensi), dan parameter pergeseran menentukan posisi jendela bergerak dalam domain waktu. $S(t)$ adalah riwayat waktu sinyal. Persamaan (5.5) disebut sebagai wavelet, yang merupakan bagian kedua dari Persamaan (5.4). Fungsi jendela dasar tanpa parameter skala dan pergeseran disebut sebagai wavelet induk.

$$\Psi_{a,b}(t) = |a|^{-0.5\psi} \left(\frac{t-b}{a} \right) \quad (5.5)$$

Wavelet induk yang digunakan dalam penelitian ini adalah wavelet Gabor, yang didasarkan pada fungsi Gaussian. Hasil analisis wavelet berupa koefisien wavelet untuk berbagai kombinasi waktu dan frekuensi yang disajikan dalam diagram kontur atau spektrogram. Spektrum wavelet 3D juga dapat disajikan sebagai gambar 2D dan digunakan sebagai masukan untuk algoritma pemrosesan gambar.

Entropi Shannon

Entropi Shannon atau informasi diperkenalkan oleh Shannon. Parameter ini mengkuantifikasi keacakan suatu variabel acak. Jika probabilitas suatu peristiwa tinggi, kemunculan peristiwa tersebut sudah diperkirakan dan tidak mengejutkan; oleh karena itu, informasi yang diberikan sangat sedikit. Konsep ini dapat digunakan dalam pemrosesan sinyal dan emisi akustik. Berbagai metode direkomendasikan untuk menghitung entropi sinyal dalam literatur. Metode-metode tersebut meliputi: entropi amplitudo tegangan, entropi fitur, dan entropi transformasi Fourier cepat (FFT).

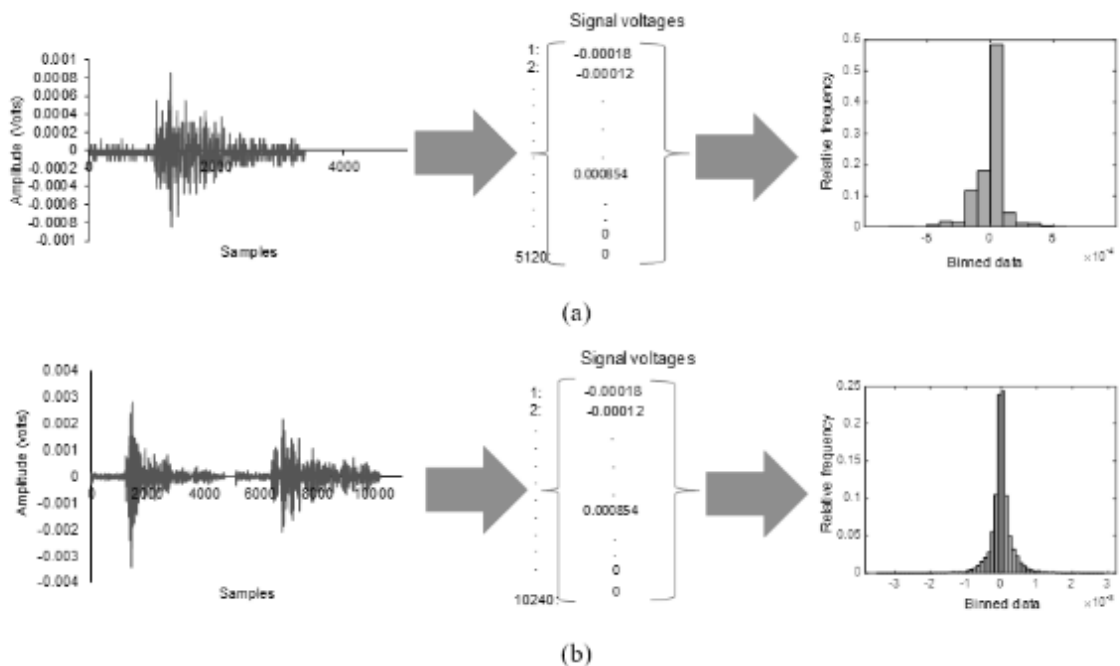
Dalam entropi tegangan, distribusi tegangan amplitudo sinyal AE diperkirakan dalam berbagai bin. Ukuran bin direkomendasikan sedekat mungkin dengan resolusi akuisisi data AE. Distribusi menunjukkan frekuensi relatif arus dalam interval tegangan yang berbeda, dan

entropi untuk tegangan dihitung menggunakan persamaan berikut (persamaan entropi Shannon):

$$Entropy = - \sum_{i=1}^n P(x_i) * \log(P(x_i)) \quad (5.6)$$

Dalam persamaan tersebut, n adalah jumlah bin dalam setiap sinyal. Bin yang didefinisikan dalam setiap sinyal direpresentasikan sebagai x_i dan $P(x_i)$ adalah frekuensi relatif setiap bin yang dihitung berdasarkan histogram sinyal. Dalam metode ini, diasumsikan bahwa perubahan tegangan konstan dan independen antar sampel. Entropi hit dapat dihitung secara independen maupun kumulatif. Metode pertama disebut entropi tegangan diskrit (DVE), dan metode kedua disebut entropi tegangan global (GVE). Kedua prosedur tersebut diilustrasikan pada Gambar 5.6.

Sinyal pada Gambar 5.6 memiliki laju pengambilan sampel 5 juta sampel per detik. Pada Gambar 5.6a, histogram dihitung secara individual untuk setiap hit, sedangkan pada Gambar 5.6b, histogram dihitung dengan mempertimbangkan sebuah hit dan hit yang terjadi sebelumnya.

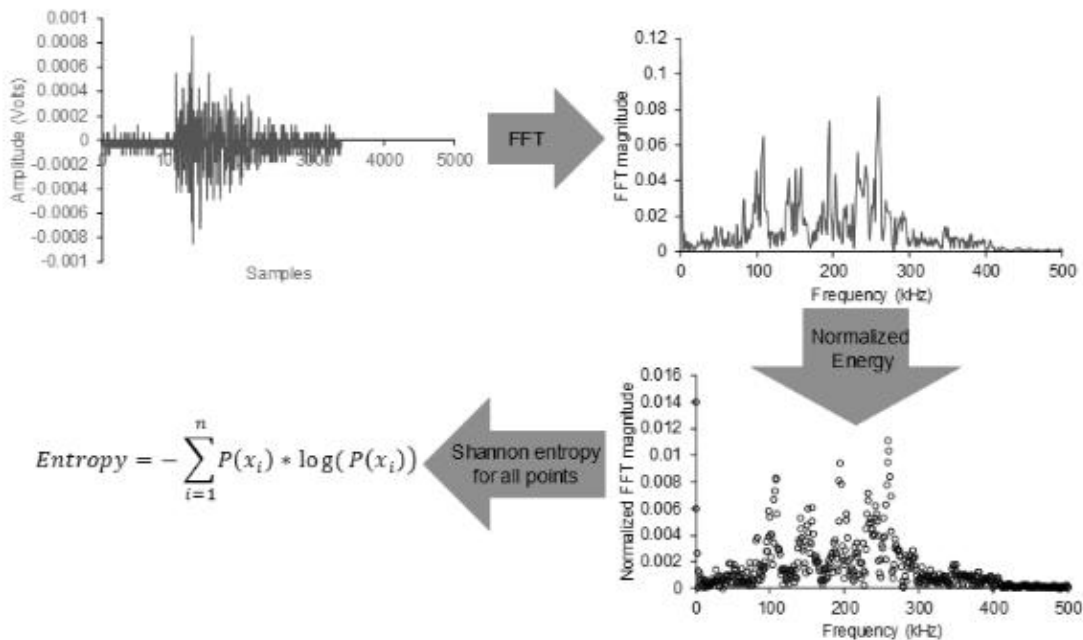


Gambar 5.6: Entropi tegangan dihitung dalam dua prosedur. (a) Entropi tegangan diskrit; (b) Entropi tegangan global.

Entropi hitungan adalah entropi fitur, yang dapat dihitung menggunakan dua prosedur. Hitungan dalam AE didefinisikan sebagai jumlah waktu tegangan sinyal melebihi ambang batas yang ditetapkan dalam sistem.

Metode pertama sangat mudah, dan probabilitasnya diperkirakan dengan membagi hitungan untuk setiap hit dalam waktu tertentu dengan jumlah kumulatif hit yang terjadi sebelum waktu tersebut. Entropi dihitung menggunakan Persamaan (5.6). Metode ini disebut sebagai CE dalam dokumen ini. Prosedur kedua disebut sebagai CE_CDF karena fungsi distribusi kumulatif (CDF) diperkirakan menggunakan metode CDF empiris, dan fungsi distribusi probabilitas (PDF) yang sesuai diekstraksi dari CDF. Entropi juga diperkirakan menggunakan Persamaan (5.6) dalam metode ini.

Entropi FFT dihitung menggunakan spektrum sinyal FFT yang dinormalisasi. Spektrum yang dinormalisasi diasumsikan sebagai distribusi probabilitas, dan entropi Shannon diperkirakan menggunakan spektrum FFT dan Persamaan. (5.6). Gambar 5.7 menunjukkan cara menghitung entropi FFT.



Gambar 5.7: Entropi FFT.

Metode Pembelajaran Mesin dan Pengelompokan


Metode pembelajaran mesin dan pengelompokan dapat dikategorikan ke dalam metode berbasis data, yang disebut sebagai algoritma untuk mengenali pola dan kluster dalam suatu set data serta memprediksi dan mengambil keputusan dari data baru tersebut. Berikut ini, beberapa algoritma umum dijelaskan.

k-means

Salah satu metode klasifikasi tanpa pengawasan yang paling sederhana dan paling awal adalah pengelompokan k-means. Algoritma ini dimulai dengan memilih k sentroid (jumlah kluster), yang merupakan parameter yang ditentukan pengguna. Kemudian, setiap set data ditetapkan ke sentroid terdekat, membentuk kluster baru. Sentroid dihitung ulang berdasarkan kluster baru. Proses ini diulang, dan titik-titik sentroid diperbarui hingga selisih

antara titik-titik sentroid baru dan sebelumnya menjadi tidak signifikan. Gambar 5.8 menunjukkan cara kerja algoritma dalam ruang 2D.

Tebakan awal untuk sentroid kluster berpengaruh pada hasil klasifikasi. Metode umum untuk memulai algoritma ini adalah memilih sentroid secara acak, yang terkadang menghasilkan klasifikasi yang buruk. Ada beberapa metode yang direkomendasikan untuk meningkatkan tebakan awal. Salah satu metodenya adalah memilih sentroid awal secara acak beberapa kali dan memilih susunan sentroid terbaik dengan rata-rata kesalahan kluster terendah.



Gambar 5.8: Gambar skema algoritma k-means untuk tiga kluster. (a) Iterasi 1; (b) Iterasi 2; (c) Iterasi 3; (d) Iterasi 4.

Metode lainnya adalah mengambil sampel data dan mengelompokkannya menggunakan pengelompokan hierarkis. Metode ini berkinerja baik jika kumpulan data tidak besar (beberapa ratus hingga beberapa ribu) dan jumlah kluster yang diinginkan kecil dibandingkan dengan kumpulan data. Metode umum lainnya adalah memilih titik terjauh dari sentroid yang dipilih pada awalnya. Metode yang terakhir mungkin tidak efektif ketika kumpulan data memiliki outlier. Setelah memilih sentroid awal, jarak antara data dan sentroid dihitung menggunakan ukuran kedekatan dan setiap titik data ditetapkan ke titik sentroid terdekat. Sentroid dalam kluster dihitung menggunakan persamaan berikut:

$$c_i = \frac{1}{m_i} \sum_{x \in C_i} x \quad (5.7)$$

di mana, m adalah jumlah titik data dalam kluster ke- i (C) dan x adalah titik data dalam ruang yang ditentukan untuk pengelompokan, c adalah pusat massa untuk kluster ke- i (C). Fungsi objektif untuk optimasi dalam ruang Euclidian dapat berupa jumlah galat kuadrat (SSE) dalam kluster. Galat yang lebih rendah untuk setiap klasifikasi menunjukkan kinerja pengelompokan yang lebih tinggi dan hamburan yang lebih sedikit dalam kelompok yang dihasilkan.

Pengelompokan Hirarkis Aglomeratif

Algoritma hierarkis aglomeratif adalah pendekatan pengenalan pola tanpa pengawasan, yang mencakup tiga langkah utama: perhitungan jarak, pengelompokan data ke

dalam kluster, dan penentuan jumlah kelompok. Hasil pengelompokan hierarkis biasanya disajikan dalam grafik seperti pohon yang disebut dendrogram. Bagian terpenting dari algoritma ini adalah menghitung kedekatan antara dua kluster. Berbagai metode digunakan untuk menghitung kedekatan antar kluster, seperti: tautan tunggal (*single link*), yang menghitung jarak antara dua titik terdekat dalam dua kelompok; tautan lengkap (*complete link*), yang menghitung kedekatan antara titik terjauh dalam dua kluster, dan rata-rata grup (*group average*), yang menghitung jarak rata-rata antara titik-titik dalam dua kelompok. Selain metode yang telah disebutkan, prosedur Ward juga dapat digunakan untuk menghitung kedekatan.

Dalam proses ini, kluster disajikan berdasarkan sentroidnya, dan kriteria untuk menggabungkan dua kluster adalah meminimalkan jumlah kuadrat jarak titik-titik dalam kelompok. Jumlah kluster ditentukan berdasarkan tinggi setiap tautan terhadap tinggi rata-rata koneksi di bawah dendrogram data. Prosedur untuk pengelompokan hierarki aglomeratif ditunjukkan dalam diagram alir pada Gambar 5.9.



Gambar 5.9: Pengelompokan hierarkis aglomeratif.

Analisis Komponen Utama


Analisis komponen utama (PCA) adalah metode untuk mengurangi dimensionalitas suatu set data. Banyak fitur dapat diekstraksi dari sinyal AE, seperti durasi, jumlah, amplitudo, frekuensi puncak, energi, dll. Namun, bekerja dengan semua fitur dan menemukan hubungan di antara mereka sulit. PCA dapat mengurangi dimensionalitas suatu set data dengan memproyeksikan data pada koordinat baru. Input untuk PCA adalah matriks di mana kolom adalah fitur (variabel) dan baris adalah observasi (hit). PCA awalnya menghitung kovariansi dari matriks input.

Kemudian, analisis nilai eigen dilakukan pada matriks kovariansi, menghasilkan nilai eigen dan vektor eigen. Jumlah nilai eigen dan vektor eigen sama dengan jumlah fitur dalam matriks input. Vektor eigen memiliki komponen yang sama dengan jumlah fitur. Nilai eigen dan vektor eigen yang bersesuaian diurutkan dari nilai terbesar ke terkecil. Kemudian, matriks masukan asli dipindahkan ke ruang baru dengan mengalikan matriks yang berisi semua vektor eigen. Berdasarkan nilai eigen, komponen utama yang paling tidak penting dapat dihapus tanpa kehilangan informasi yang signifikan.

Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) dapat dianggap sebagai pendekatan pengenalan pola terawasi, yang dilatih menggunakan data berlabel untuk mengklasifikasikan data baru yang tidak berlabel atau untuk mengestimasi nilai berdasarkan data masukan baru.

JST multilapis memiliki tiga lapisan utama: lapisan masukan, tersembunyi, dan keluaran. Lapisan perantara antara lapisan masukan dan keluaran disebut sebagai lapisan tersembunyi, di mana JST mempelajari hubungan antara data masukan dan target. Algoritma ini bertujuan untuk memecahkan masalah optimasi agar keluaran JST sedekat mungkin dengan nilai target. Dalam prosedur ini, faktor bobot untuk setiap neuron sering diperbarui untuk mencapai nilai target. Arsitektur skematis ANN multilapis ditunjukkan pada Gambar 5.10.



Gambar 5.10: Jaringan saraf tiruan skematis dengan dua lapisan tersembunyi.

Data masukan dan target diberikan ke model ANN. Algoritma ANN memulai iterasi dengan nilai bobot awal (dipilih secara acak) dan menghitung nilai keluaran, lalu membandingkannya dengan nilai target yang diberikan ke model. Kesalahan dihitung, dan vektor bobot diperbarui. Prosedur ini berlanjut hingga nilai keluaran mendekati nilai target sedekat mungkin. Fungsi aktivasi nonlinier seperti fungsi sigmoid atau tangen hiperbolik dapat digunakan untuk menghasilkan hubungan nonlinier antara nilai target dan masukan.

Data masukan biasanya dipisahkan menjadi tiga set data: data latih, validasi, dan uji. Set data latih digunakan untuk melatih jaringan. Data validasi dipilih dari data masukan untuk mengevaluasi jaringan selama proses pelatihan. Data ini digunakan untuk membantu jaringan digeneralisasi untuk set data baru. Data uji merupakan set data independen untuk menguji kinerja jaringan yang telah dilatih.

Jaringan Saraf Tiruan Autoencoder Bertumpuk

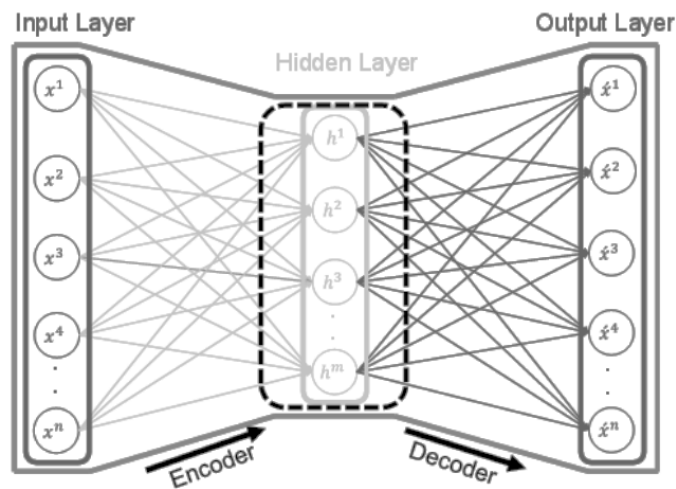
Algoritma ini merupakan metode pembelajaran mendalam. Jaringan pembelajaran mendalam memiliki kemampuan untuk mengekstrak fitur dari data mentah, alih-alih menggunakan fitur yang telah disiapkan. Metode pembelajaran mendalam dapat digunakan dalam visi komputer, pemrosesan audio, pemrosesan sinyal, dan pemrosesan bahasa.

Setiap autoencoder memiliki tiga lapisan yang mirip dengan ANN: lapisan masukan, tersembunyi, dan keluaran. Autoencoder adalah jaringan pembelajaran tanpa pengawasan (*unsupervised learning network*), yang menemukan pola tertanam dalam suatu set data dengan mengondensasi data masukan asli dan merekonstruksi set data tersebut dari data yang telah dikondensasi. Struktur skema lapisan autoencoder yang berbentuk seperti leher botol (*bottleneck*) pada lapisan tersembunyi ditunjukkan pada Gambar 5.11.

Jika data masukan memiliki n dimensi $\{x^1, x^2, x^3, \dots, x^n\}$ dan lapisan tersembunyi memiliki m dimensi, dengan $m < n$, data masukan akan dikondensasi menggunakan fungsi pengkodean nonlinier. Hasil pengkodean melewati fungsi dekode dan direkonstruksi di lapisan keluaran $\{\hat{x}^1, \hat{x}^2, \hat{x}^3, \dots, \hat{x}^n\}$. Fungsi pengkodean (E) dan dekode (D) dapat direpresentasikan dalam persamaan berikut:

$$E(x) = S_{\theta}(wx + b) \tag{5.8}$$

$$D(h) = S_{\theta'}(w'h + b') \tag{5.9}$$




Gambar 5.11: Struktur Autoencoder.

Dalam persamaan di atas, w dan w' adalah bobot fungsi encoder dan decoder, dan masing-masing merupakan matriks $m \times n$, sedangkan b dan b' adalah vektor bias untuk fungsi encoder dan decoder. Fungsi aktivasi dapat berupa (i) sigmoid, (ii) tangen hiperbolik, atau (iii) kustom. Tujuan autoencoder adalah meminimalkan kesalahan antara versi data asli dan versi hasil rekonstruksi.

Jaringan autoencoder bertumpuk dapat dibangun dengan menumpuk dua atau beberapa autoencoder. Autoencoder pertama mendapatkan fitur dari data masukan, yang merupakan masukan untuk autoencoder berikutnya. Fitur baru kemudian diekstraksi dari autoencoder kedua. Prosedur ini akan dilanjutkan hingga autoencoder terakhir. Fitur yang dihasilkan dari lapisan autoencoder terakhir digunakan sebagai input untuk klasifikasi, menggunakan lapisan softmax, atau prediksi menggunakan lapisan regresi.

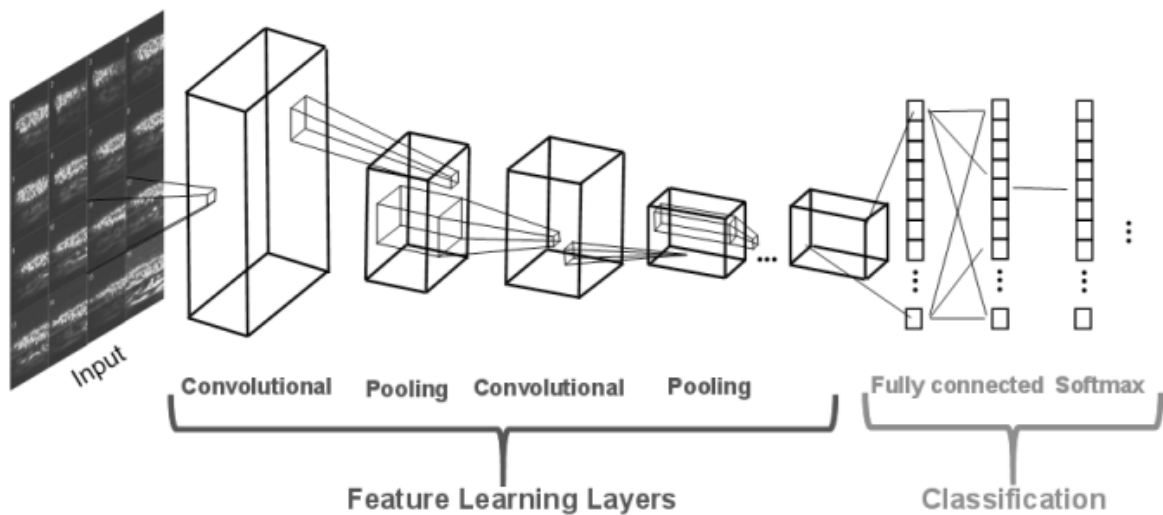
Bagian dari autoencoder bertumpuk ini diawasi, dan jaringan dilatih untuk label atau nilai yang ditetapkan. Jaringan dapat disetel halus melalui backpropagation untuk meningkatkan kinerjanya. Struktur skema autoencoder bertumpuk dengan dua autoencoder ditunjukkan pada Gambar 5.12 yang menunjukkan bagaimana bentuk gelombang AE atau spektrum FFT AE dapat digunakan sebagai set data input untuk autoencoder bertumpuk.



Gambar 5.12: Jaringan autoencoder bertumpuk dengan dua autoencoder dan lapisan klasifikasi.

Jaringan Saraf Tiruan Konvolusional

Jaringan saraf tiruan konvolusional (CNN) adalah metode pembelajaran mendalam yang paling banyak digunakan untuk pengenalan gambar dan sinyal.



Gambar 5.13: Struktur CNN yang disederhanakan untuk klasifikasi kontur wavelet.

Komponen utama CNN adalah lapisan masukan, lapisan ekstraksi fitur, dan lapisan terhubung penuh. Struktur skema CNN diilustrasikan pada Gambar 5.13. Data masukan untuk klasifikasi gambar berupa tensor dengan (jumlah gambar) × (tinggi gambar) × (lebar gambar) × (saluran masukan) dan biasanya dibagi menjadi set data pelatihan dan pengujian. Lapisan ekstraksi fitur mencakup lapisan konvolusional dan lapisan pengumpulan.

Pada lapisan ekstraksi fitur, algoritma mengekstrak fitur dan belajar membedakannya. Data AE dapat disajikan sebagai gambar menggunakan transformasi wavelet. Gambar yang dihasilkan disisipkan sebagai set masukan dalam CNN. Setiap gambar melewati beberapa filter konvolusional, yang menyoroti karakteristik spesifik gambar tersebut. Dalam lapisan konvolusional, beberapa kernel (filter) digunakan untuk memfilter data masukan dan mengekstrak fitur. Misalnya, keluaran peta fitur ke-*j* pada lapisan konvolusional ke-*n* dihitung dengan persamaan berikut:

$$x_j^n = f \left(\sum_{i=1}^M x_i^{n-1} * k_y^n + b_j^n \right) \quad (5.10)$$

di mana, $f()$ adalah fungsi aktivasi, " $*$ " menunjukkan konvolusi antara data dan kernel, k_{ij}^n adalah kernel filter ke- n , b_j^n adalah parameter bias untuk filter ke- n , x_i^{n-1} adalah peta fitur masukan dari lapisan konvolusional sebelumnya ($n - 1$).

Lapisan penggabungan mengambil sampel peta fitur dari lapisan konvolusional sebelumnya dan mengurangi ukuran fitur. Jika pengambilan sampel turun tidak dilakukan dari lapisan ke lapisan, proses komputasi menjadi mahal, dan model rentan terhadap overfitting. Oleh karena itu, lapisan penggabungan diperlukan setelah setiap lapisan konvolusional. Pengambilan sampel turun dapat dilakukan menggunakan pengumpulan maksimum atau pengumpulan rata-rata. Fungsi umum untuk lapisan penggabungan adalah sebagai berikut:

$$x_j^n = f(\beta_{jS_{down}}^n (x_j^{n-1}) + b_j^n) \quad (5.11)$$

Dalam persamaan tersebut, $f()$ adalah fungsi aktivasi, β_j^n dan b_j^n mengacu pada bias perkalian dan aditif, S_{down} adalah fungsi down-sampling, x_j^{n-1} adalah peta fitur input, dan x_j^n adalah output setelah down-sampling.

Lapisan terhubung penuh biasanya ditempatkan di ujung jaringan dan mentransfer semua fitur dari lapisan pengumpulan terakhir ke vektor fitur. Fungsi untuk lapisan terhubung penuh memiliki bobot w^J dan bias b^J seperti yang ditunjukkan di bawah ini:

$$x^J = f(x^{j-1}w^J + b^J) \quad (5.12)$$

di mana:

f adalah fungsi aktivasi untuk lapisan terhubung penuh, x^{j-1} dan x^j adalah masukan dan keluaran lapisan tersebut. CNN memiliki beberapa parameter dan struktur yang kompleks. Merancang dan melatih CNN dari awal sangat menantang, memakan waktu, dan membutuhkan data dalam jumlah besar. Oleh karena itu, konsep pembelajaran transfer diperkenalkan untuk mengatasi tantangan tersebut dengan CNN baru. Pembelajaran transfer didasarkan pada CNN yang telah dilatih dengan data dalam jumlah besar.

Jaringan yang telah dilatih sebelumnya diumpankan data baru (gambar) melalui lapisan CNN yang lebih dalam. Laju pembelajaran untuk lapisan awal (lapisan yang ditransfer) harus dikurangi secara drastis, dan faktor laju pembelajaran untuk lapisan terhubung penuh harus ditingkatkan. Beberapa CNN pra-terlatih yang terkenal untuk pembelajaran transfer adalah GoogLeNet.


5.4 PENGGUNAAN METODE BERBASIS DATA DALAM DATA AE

Pada bagian ini, beberapa contoh penggunaan metode berbasis data dalam data AE dibahas.

Retak Korosi Tegangan


Penerapan AE dalam memantau kerusakan akibat SCC pada baja tahan karat telah dipaparkan oleh beberapa peneliti. Beberapa peneliti berfokus pada mode fraktur dan perbedaan sinyal antara mekanisme retak intergranular dan transgranular. Baru-baru ini, sebuah studi penelitian dilakukan mengenai kemampuan AE untuk mengenali dan melokalisasi SCC pada pelat baja tahan karat, yang menyerupai material struktur DCSS di University of South Carolina. Gambar 5.14 menunjukkan spesimen skala besar dan kecil yang digunakan untuk uji SCC. Spesimen besar berukuran 5029 mm × 1524 mm × 16 mm dan memiliki empat takik. Spesimen skala kecil berukuran 305 mm × 311 mm × 16 mm dengan satu takik.

Larutan kalium tetratrat (K₂S₄O₆) digunakan sebagai elektrolit untuk menciptakan lingkungan korosif pada lokasi takik. Sebuah tabung plastik ditempatkan pada takik dan larutan dituangkan ke dalamnya. pH larutan diturunkan dengan menambahkan asam sulfat, yang mempercepat reaksi korosi. Permukaan atas pelat baja pada lokasi setiap takik mengalami tegangan tarik akibat pembengkokan di luar bidang. Pelat baja tersebut diberi perlakuan panas sebelum pengujian untuk tujuan sensitisasi, seperti yang ditunjukkan pada Gambar 5.1. Retakan pertama yang terlihat diamati pada hari ke-9 percobaan, seperti yang ditunjukkan pada Gambar 5.15.



(a)


Tabung Solusi
Sensor AE
Plat Besi
Tab yang dilas



Pengukur Regangan
Akuisisi Data Strain

(b)


Gambar 5.14: (a) Pelat baja tahan karat skala besar; (b) Pelat baja tahan karat skala kecil




Gambar 5.15: Retakan visual: (a) Inisiasi pada hari ke-9; (b) Perambatan retakan pada hari ke-19.

Sinyal ditransfer ke domain frekuensi menggunakan FFT. Area di bawah spektrum FFT dibagi berdasarkan interval frekuensi. Energi yang terkandung dalam interval frekuensi tersebut diestimasi. Misalnya, frekuensi Nyquist, yaitu 500 kHz, dibagi menjadi sepuluh interval yang sama besar. Oleh karena itu, sepuluh nilai energi dihitung dan digunakan sebagai fitur sinyal. PCA dilakukan pada data untuk mengurangi dimensi kumpulan data. Empat komponen utama pertama, yang mencakup 93% varians kumulatif, dipilih untuk pengenalan pola.

Metode pengelompokan hierarkis aglomeratif digunakan untuk mengklasifikasikan data berdasarkan fitur-fitur baru yang diperoleh dari PCA, dan metode Ward digunakan untuk memperkirakan kesamaan dan menghubungkan objek-objek tersebut. Data yang terklasifikasi diilustrasikan dalam tiga komponen utama pertama dalam ruang 3D pada Gambar 5.16. Distribusi energi rata-rata dalam hal frekuensi dan kekuatan sinyal kumulatif dalam hal waktu eksperimen untuk ketiga klaster ditunjukkan pada Gambar 5.17.




Gambar 5.16: (a) Dendrogram pengelompokan; (b) Data dalam ruang komponen utama.




Gambar 5.17: (a) Distribusi energi rata-rata; (b) Amplitudo dan CSS terhadap waktu untuk data terklasifikasi.

Lonjakan CSS yang signifikan terjadi pada hari ke-8, yang mendekati hari (hari ke-9) di mana inisiasi retakan diamati secara visual (Gambar 5.17b). Lebih lanjut, Klaster 3 memiliki akumulasi energi terbesar pada frekuensi di atas 200 kHz (Gambar 5.17a), dan merupakan kontributor terbesar dalam lompatan CSS yang signifikan (Gambar 5.17b).



Gambar 5.18: Koefisien evolusi determinasi selama uji SCC untuk nilai b global



Gambar 5.19: (a) Zona pada pelat skala besar; (b) Akurasi lokalisasi zona untuk ANN dan autoencoder bertumpuk.

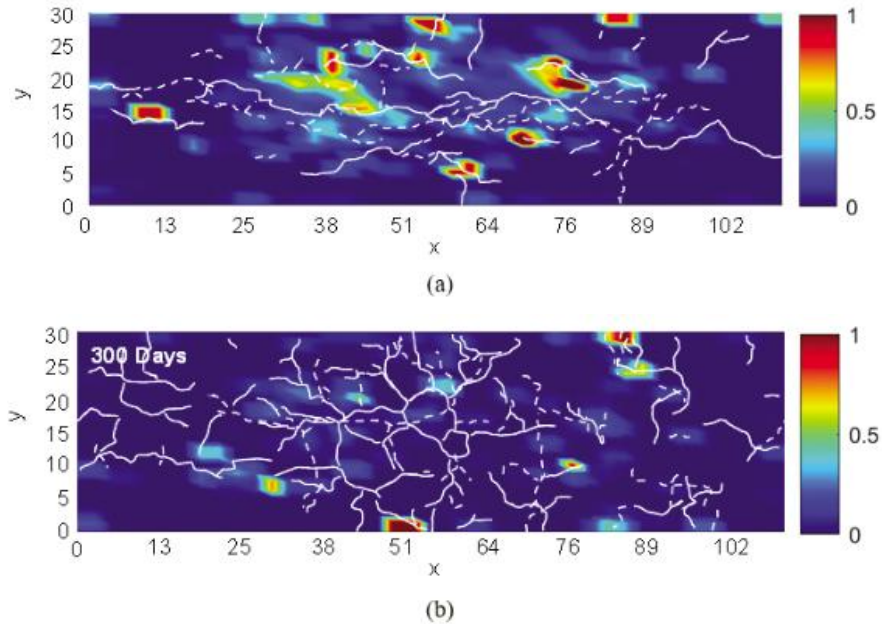
Koefisien determinasi yang dihitung dari nilai-b global dalam beberapa kasus selama pengujian disajikan pada Gambar 5.18. Tren temporal diamati, di mana peningkatan koefisien determinasi diikuti oleh penurunan tajam setelah retakan pertama terlihat. JST dan autoencoder bertumpuk dapat digunakan untuk lokalisasi zonal dalam struktur skala besar menggunakan jumlah sensor minimal. Masukan untuk model JST adalah fitur parametrik seperti durasi, amplitudo, waktu naik, frekuensi rata-rata, akar kuadrat rata-rata, energi, dan frekuensi puncak. Namun, set data masukan untuk model autoencoder bertumpuk adalah bentuk gelombang AE (deret waktu). Pelat skala besar dibagi menjadi lima zona, seperti yang ditunjukkan pada Gambar 5.19a. Hasil lokasi sumber menunjukkan peningkatan yang signifikan menggunakan autoencoder bertumpuk pada Gambar 5.19b.

Reaksi Alkali-Silika


Beberapa penelitian terbaru berfokus pada penggunaan emisi akustik untuk memantau degradasi ASR pada struktur beton. Beberapa investigasi telah dilakukan oleh University of South Carolina mengenai ASR pada beton bertulang dan tak bertulang serta spesimen skala besar. Pengenalan pola hierarkis aglomeratif yang dikombinasikan dengan PCA digunakan untuk mengklasifikasikan data AE berdasarkan fitur frekuensi-energi yang diekstraksi dari spektrum FFT. Lebih lanjut, evolusi temporal data untuk berbagai kluster dievaluasi pada spesimen skala besar dan menengah.

Distribusi statistik spasial kejadian AE digunakan untuk mengidentifikasi perbedaan antara mekanisme kerusakan struktur dengan dan tanpa pekekangan. Gambar 5.20 menyajikan tomografi kontur kejadian AE untuk spesimen terkurung dan tidak terkurung. Berdasarkan Gambar 5.20 dan 5.5, pola distribusi kejadian untuk spesimen terkurung berbeda dengan spesimen tidak terkurung. Kejadian untuk spesimen terkurung sebagian besar terjadi di bagian tengah sepertiga lebar spesimen (arah Y) dibandingkan dengan spesimen tidak

terkurung. Probabilitas kejadian di bagian tengah sepertiga lebar spesimen dihitung pada waktu yang berbeda selama ASR untuk kedua spesimen dan ditunjukkan pada Gambar 5.21.




Gambar 5.20: Tomografi kejadian AE: (a) spesimen terbatas; (b) spesimen tidak terbatas (Soltangharaei et al., 2020a).



Gambar 5.21: Evolusi temporal probabilitas relatif tengah kejadian untuk spesimen yang dikurung dan tidak dikurung.

Entropi Shannon dapat digunakan untuk membedakan berbagai fase selama ASR, sebagaimana disebutkan pada Bagian selanjutnya. Hasil penghitungan entropi menggunakan CDF (CE_CDF) untuk spesimen terkurung dan tidak terkurung ditunjukkan pada Gambar 5.22. Entropi awalnya meningkat dan kemudian menurun secara bertahap. Dengan kata lain, keacakan data meningkat selama tahap pertama, yang dapat dikaitkan dengan pembentukan retakan mikro pada spesimen beton. Seiring berjalannya ASR, retakan mikro tersebut menyatu dan membentuk retakan makro di lokasi tertentu, sehingga mengurangi keacakan data.

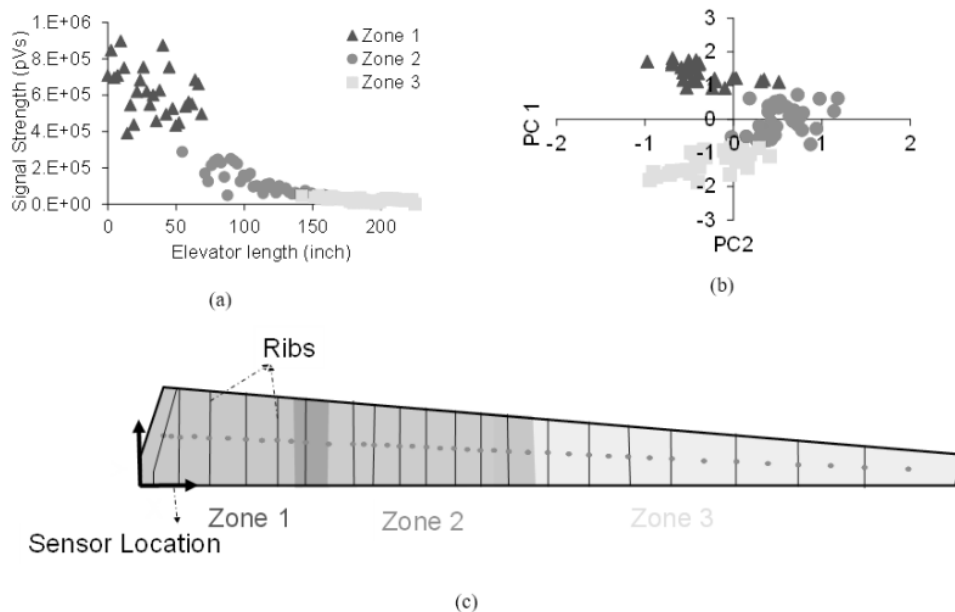


Gambar 5.22: Menghitung entropi untuk: (a) spesimen terkekang; (b) spesimen tak terkekang

Dampak pada Elevator Pesawat

Material komposit serat karbon digunakan dalam struktur kedirgantaraan seperti pesawat terbang karena kekuatannya yang tinggi dan kepadatannya yang rendah. Namun, material ini mungkin rentan terhadap dampak puing dan hujan es. Oleh karena itu, sistem pemantauan kesehatan struktural, yang dapat melokalisasi dan menentukan tingkat dampak, sangat penting untuk operasi yang aman.


Model lokalisasi zonal berdasarkan metode berbasis data dikembangkan menggunakan metode pengenalan pola dan ANN. Data dikumpulkan melalui sensor AE broadband tunggal (yang terpasang pada rangka elevator) dengan membenturkan permukaan struktur menggunakan impaktor baja yang ditunjukkan pada Gambar 5.3. Lokasi dampak ditunjukkan pada Gambar 5.23c. K-means dan PCA digunakan untuk mengklasifikasikan data di sepanjang elevator. Fitur parametrik seperti durasi, waktu naik, kekuatan sinyal, frekuensi rata-rata, amplitudo, jumlah, dan jumlah hingga puncak digunakan untuk klasifikasi. Fitur-fitur tersebut berevolusi seiring sumber tumbukan bergerak menjauh dari sensor.



Gambar 5.23: Hasil K-means: (a) variasi kekuatan sinyal data AE sepanjang elevator; (b) PCA; (c) batas zona.

PCA dilakukan pada fitur parametrik untuk mengurangi dimensi data (Gambar 5.23b). Data ditunjukkan pada Gambar 5.23b dalam ruang komponen utama 2D. Komponen utama yang dihasilkan digunakan sebagai fitur data dalam metode k-means. Algoritma tersebut mengklasifikasikan data ke dalam tiga klaster, yang menunjukkan batas zona untuk model lokasi sumber zona (Gambar 5.23a).

Data diberi label berdasarkan hasil k-means (zona 1, zona 2, zona 3). Data berlabel tersebut kemudian dimasukkan ke dalam model ANN yang dikembangkan dengan dua lapisan tersembunyi (25 neuron di setiap lapisan) dan lapisan keluaran regresi. Set data dibagi menjadi tiga subset: pelatihan, validasi, dan pengujian. Jaringan Saraf Tiruan (JST) dilatih beberapa kali untuk mendapatkan hasil optimal dengan kesalahan pengujian terendah. JST yang telah dilatih dapat digunakan untuk memperkirakan lokasi zonal tumbukan pada elevator. Fitur dari setiap tumbukan dapat digunakan sebagai input untuk model. Hasil model akan berupa nomor zona. Kesalahan mislokalisasi dikurangi dengan mempertimbangkan tumpang tindih pada batas zona (Gambar 5.23c) seperti yang ditunjukkan pada Gambar 5.24.



Gambar 5.24: Kesalahan ANN untuk lokalisasi sumber zonal elevator.

Metode pembelajaran mendalam seperti jaringan autoencoder dapat digunakan untuk mengembangkan model lokasi sumber zonal untuk elevator menggunakan data mentah (sinyal dalam domain waktu atau frekuensi) dan diharapkan memberikan hasil yang lebih presisi untuk model dengan nomor zona yang lebih besar, seperti yang dibahas dalam, untuk pelat baja dan elevator skala besar. Namun, waktu komputasi dan pelatihan untuk pembelajaran mendalam jauh lebih lama daripada model ANN. Selain itu, penyimpanan data yang lebih besar diperlukan untuk data masukan metode pembelajaran mendalam. Kedua kelemahan ini menimbulkan keterbatasan untuk akuisisi data on-flight dan sistem pengambilan keputusan, sehingga membuat model ANN lebih cocok untuk aplikasi spesifik ini pada saat ini.

5.5 KESIMPULAN

AE merupakan metode nondestruktif untuk mendeteksi kerusakan pada berbagai struktur akibat mekanisme yang berbeda. Salah satu keunggulan metode ini dibandingkan teknik lain adalah sensitivitas sensor AE yang tinggi, sehingga memungkinkan perolehan data kerusakan skala mikro hingga makro yang lebih banyak. Keunggulan ini menghadirkan tantangan dalam hal analisis dan pengelolaan data.

Tantangan tersebut dapat dikaitkan dengan pengumpulan data asing selama akuisisi atau mungkin terkait dengan analisis dan interpretasi data. Yang pertama diatasi dengan menyediakan berbagai pendekatan penyaringan dan melindungi sambungan listrik, sementara yang kedua dapat ditangani dengan berbagai metode berbasis data, beberapa di antaranya disajikan dalam bab ini. Studi kasus mengilustrasikan penerapan beberapa metode analisis untuk data AE yang diperoleh dari berbagai kondisi pembebanan atau tegangan yang diterapkan pada struktur komposit baja, beton, dan bertulang serat.

Implementasi algoritma dan model berbasis data yang lebih kompleks untuk menganalisis data AE menjadi lebih memungkinkan seiring dengan kemajuan perangkat keras dan sistem komputasi. Selain itu, metode-metode ini dapat menjadi langkah maju dalam pengembangan sistem otonom terintegrasi untuk akuisisi data, analisis data, interpretasi data, estimasi kondisi struktural, dan pengambilan keputusan. Algoritma pembelajaran mendalam seperti CNN, autoencoder, dan jaringan saraf berulang seperti jaringan memori jangka pendek (LSTM) direkomendasikan untuk digunakan dalam menganalisis data AE yang kompleks dan memperkirakan dependensi data dalam domain waktu.

BAB 6

DETEKSI OTOMATIS RETAK BETON STRUKTURAL

6.1 PENDAHULUAN

Beton struktural merupakan material bangunan serbaguna yang banyak digunakan untuk infrastruktur. Beton memiliki konduktivitas yang rendah dan komponen-komponennya biasanya berukuran besar dan tahan api. Selama kebakaran pasca-flashover yang merusak, suhu di dalam bangunan dan struktur dapat melebihi 800–1000°C dengan fluks panas lebih dari 100 kW/m². Namun, beton struktural mampu menahan paparan suhu yang lebih tinggi dengan baik dibandingkan dengan material bangunan lainnya. Saat ini, beton struktural digunakan dalam berbagai aplikasi (misalnya, dinding api, proteksi pasif, elemen penahan beban pada bangunan tinggi) karena sifat tahan api yang dimilikinya.

Penutup beton menciptakan penghalang yang efektif dalam melindungi baja tulangan dan baja struktural pada konstruksi bertulang dan komposit. Meskipun elemen beton memiliki sifat termal yang sangat baik, setelah suhu sekitar 500°C, beton sebagai material akan kehilangan sebagian besar kekuatannya. Selain itu, pengaruh suhu antara 500°C dan 800°C dapat menjadi kritis, karena pada tahap ini terjadi spalling dan retak termal biasanya terjadi. Kehilangan massa yang cepat terjadi pada beton pada suhu di atas 800°C, dan kehilangan kekuatan diketahui berbanding lurus dengan kehilangan kadar air yang terjadi. Sifat mekanik dan termal beton juga bervariasi seiring dengan peningkatan suhu.



Gambar 6.1: Contoh kerusakan akibat kebakaran yang luas pada bangunan beton bertulang yang menunjukkan (a) spalling, (b) tekuk kolom, dan (c) retak luas pada soffit di sepanjang garis tulangan.

Beton mengalami perubahan fisik, struktural, dan mikrostruktur yang parah akibat paparan suhu yang lebih tinggi. Efek ini dapat menyebabkan ketidakstabilan pada elemen struktural dan dapat menyebabkan skenario keruntuhan progresif. Gambar 6.1 mengilustrasikan

beberapa fenomena yang dibahas di atas, yang menunjukkan kerusakan struktural yang luas pada bangunan beton bertulang.

Beton struktural merupakan material bangunan yang disukai karena kemudahan produksinya, daya tahannya, dan sifatnya yang tidak mudah terbakar. Beton memiliki kapasitas kalor jenis yang tinggi dan konduktivitas termal yang rendah. Beton memiliki kemampuan yang sangat baik untuk menahan tegangan tekan yang timbul selama penerapan beban, meskipun memiliki kapasitas tarik yang terbatas. Oleh karena itu, penampang beton sensitif terhadap beban tarik dan gaya-gaya tersebut dapat menyebabkan retakan. Pada suhu tinggi, tegangan tarik terbentuk di dalam mikrostruktur beton akibat tekanan pori dan tegangan induksi akibat ekspansi yang dilatih ulang.

Ketika terpapar suhu tinggi, kuat tekan beton bervariasi tergantung pada jenis agregat dan ukurannya, rasio air-semen, jenis bahan tambahan, dan jenis semen. Laju paparan suhu juga berdampak pada kuat tekan sisa. Faktor-faktor yang memengaruhi perkembangan tegangan tarik induksi akibat pengekangan meliputi geometri penampang, rezim pemanasan, dan sifat termal. Retak mikro dan spalling terjadi pada beton ketika tegangan tarik melebihi kuat tarik yang diizinkan. Karena alasan ini, beton struktural lebih rentan retak di bawah beban tarik dan transversal.

Elemen struktural dirancang untuk memenuhi kriteria kekuatan dan kemudahan servis. Pada suhu tinggi, beton kehilangan kuat tekannya dan baja kehilangan kuat tariknya, sehingga modulus elastisitas dan kapasitas penampang menurun secara signifikan. Selain itu, elemen struktural yang mengalami pembebanan mengalami deformasi yang dapat memperparah retak. Ketika beton terpapar suhu tinggi, hal ini memengaruhi kuat tekan, kuat lentur, kuat lekat, kuat geser, kuat dampak, perilaku tegangan-regangan, dan modulus elastisitas. Penurunan ini mungkin disebabkan oleh pengaruh material penyusun beton, laju kenaikan, dan besarnya paparan suhu. Selama paparan suhu tinggi, putusannya ikatan antarmuka terjadi di dalam struktur mikro beton.

Kekuatan lentur beton jauh lebih rendah daripada kekuatan tekan beton karena retakan mikro yang terbentuk pada beton dapat menyebar dan melebar di bawah beban lentur. Ketika terpapar api, kekuatan lentur beton berkurang karena spalling yang terjadi di dalam struktur beton. Penurunan kekuatan lekat antara baja dan beton dapat terjadi. Dengan peningkatan suhu, terjadi penurunan cepat kekuatan tarik beton, sehingga ikatan antara beton dan baja berkurang. Laju kenaikan suhu dan durasi paparan merupakan parameter yang paling memengaruhi penurunan kekuatan tekan dan ikatan, sementara deformasi/slip meningkat.

Retak merupakan hasil dari kegagalan material lokal yang terjadi akibat peningkatan suhu pada beton struktural. Evaluasi pola, kepadatan, lebar, dan luas retakan memberikan wawasan untuk menilai tingkat kerusakan yang dialami. Penilaian perkembangan dan deteksi retakan dapat bermanfaat untuk mengukur tingkat kerusakan yang dialami. Studi sebelumnya menunjukkan bahwa kepadatan dan porositas retakan termal permukaan meningkat seiring dengan peningkatan suhu dan durasi paparan.

Deteksi dan kuantifikasi retakan merupakan area yang sedang berkembang dalam pemantauan kesehatan struktural. Penelitian dan investigasi terkait tentang deteksi dan

kuantifikasi retakan juga dapat bermanfaat untuk pekerjaan perbaikan dan rehabilitasi. Beberapa teknik komputasi telah digunakan di bidang ini sebagai alat untuk mendeteksi berbagai jenis retakan. Oleh karena itu, penelitian ini berfokus pada deteksi retakan pada beton struktural yang terpapar suhu tinggi.

Untuk menilai kapasitas menahan beban sisa secara ilmiah, diperlukan informasi mengenai distribusi suhu di dalam elemen beton dan sifat material sisa beton maupun baja. Tujuan penelitian ini adalah mendeteksi dan memperkirakan kerusakan elemen beton yang terkena api menggunakan teknik Kecerdasan Buatan (AI). Teknik berbasis pembelajaran mesin digunakan untuk mendeteksi dan mengukur kerusakan pada beton yang terkena api.

Spesimen beton dengan kuat tekan 20 hingga 50 MPa dipaparkan pada suhu tinggi sesuai kurva waktu-suhu standar (kurva ISO 834). Setelah uji api, gambar yang menunjukkan retakan pada permukaan spesimen beton diambil menggunakan kamera digital yang diproses untuk mengukur kerusakan dan memperkirakan paparan api. Korelasi yang baik diperoleh antara kuat tekan sisa dan suhu pada inti beton yang rusak akibat api, yang diukur selama percobaan. Hasil menunjukkan bahwa retakan yang terdeteksi dari teknik yang dikembangkan sesuai dengan pengamatan visual.

6.2 TEKNIK PEMROSESAN CITRA

Bagian ini memberikan informasi tentang metodologi deteksi kerusakan yang dikembangkan. Teknik-teknik tersebut berkaitan dengan analisis citra dasar yang dipadukan dengan teknik pembelajaran mesin (ML)/pembelajaran mendalam (DL) tingkat lanjut, sebagaimana disajikan secara rinci di bawah ini. Keuntungan utama deteksi retakan berbasis citra adalah menghasilkan hasil deteksi yang akurat. Metode konvensional memakan waktu dan bergantung pada pengetahuan inspektur. Deteksi dan kuantifikasi retakan berbasis citra merupakan bidang yang menjanjikan dalam visi komputer. Beberapa peneliti telah menggunakan metode berbasis visi komputer untuk menangkap dan menganalisis retakan secara efisien. Teknik berbasis visi telah diklasifikasikan ke dalam empat kategori besar, yaitu: teknik berbasis penyaringan, teknik berbasis ambang batas, teknik berbasis operator morfologi, dan teknik berbasis transformasi.

Teknik dasar deteksi retakan berbasis citra memiliki empat proses fundamental, yaitu: akuisisi citra, pra-pemrosesan, ekstraksi fitur, dan deteksi retakan. Teknik-teknik ini berbeda dalam hal jenis citra. Citra inframerah, citra ultrasonik, dan citra laser adalah beberapa sumber yang dapat digunakan. Teknik penghilangan dan peningkatan derau merupakan bagian dari teknik pra-pemrosesan. Derau biasanya terjadi karena pengaturan akuisisi citra. Variasi iluminasi, nada, dan bayangan semuanya dapat dianggap sebagai derau. Derau ini dihilangkan dengan menerapkan teknik penghilangan derau yang sesuai. Peningkatan citra dilakukan setelah proses penghilangan derau. Teknik peningkatan digunakan untuk meningkatkan garis, tepi, titik, dan kontur citra masukan. Metode deteksi retakan menggunakan citra kontras tinggi. Teknik morfologi matematis dan evaluasi kelengkungan digunakan untuk menemukan pola retakan. Pemfilteran linier digunakan untuk membedakan retakan dari latar belakang yang berderau. Citra yang telah dihaluskan diterapkan pada proses segmentasi retakan.

Retakan dikuantifikasi melalui luas retakan, keliling retakan, dan indeks kebulatan.. Untuk menghilangkan derau dari citra masukan, pemfilteran median diterapkan, dan filter multi-garis berbasis matriks hessian digunakan untuk mempertegas retakan. Retakan halus diidentifikasi menggunakan ambang batas adaptif.

Kombinasi filter dan detektor tepi digunakan untuk mengidentifikasi kerusakan. Filter median digunakan untuk menghilangkan derau pada citra masukan, dan detektor tepi Canny digunakan untuk menemukan retakan pada dinding. Metode berbasis penyaringan dasar ini sebagian besar mengadopsi teknik hibrida untuk mendeteksi retakan secara efektif, yang biasanya dikombinasikan dengan pemrosesan morfologi, penyaringan, dan teknik ambang batas. Metode berbasis transformasi juga digunakan untuk menemukan kerusakan pada citra beton. Citra tersebut dianalisis secara akurat dalam domain frekuensi. Transformasi Fourier, Transformasi Wavelet, Transformasi Curvelet, Transformasi Shearlet, dan Transformasi Ripplet telah digunakan oleh para peneliti untuk mengidentifikasi kerusakan

Transformasi Fourier Cepat dan Transformasi Haar Cepat awalnya digunakan untuk mengidentifikasi retakan pada jembatan beton. Teknik detektor tepi Sobel dan Canny juga digunakan untuk meningkatkan hasil. Transformasi Wavelet digunakan untuk mendeteksi kerusakan pada struktur beton. Koefisien wavelet digunakan untuk mendapatkan sifat retak. Transformasi Wavelet digunakan oleh banyak peneliti untuk menemukan retakan secara efisien. Fitur arah input tidak ditangkap dengan baik oleh transformasi wavelet konvensional. Oleh karena itu, transformasi wavelet multiskala dan multiarah dimanfaatkan untuk mendeteksi kerusakan. Transformasi Kurva Cepat digunakan untuk mendeteksi retakan. Analisis tekstur juga diintegrasikan dalam studi untuk menemukan retakan secara akurat. Citra masukan didekomposisi terlebih dahulu untuk menganalisis fitur masukan dalam domain frekuensi. Transformasi invers diterapkan untuk merekonstruksi citra masukan dan dengan demikian retakan teridentifikasi dengan baik.

Retakan pada struktur beton yang terdampak kebakaran telah diidentifikasi oleh Transformasi Ripplet. Tantangan utama terkait eliminasi derau, peningkatan, dan deteksi retakan disajikan dalam teknik ini. Citra masukan didekomposisi menjadi beberapa sub-pita. Fitur citra dianalisis dengan baik dalam domain Ripplet, dengan retakan termal mayor dan minor terdeteksi secara akurat. Sifat retakan dikuantifikasi melalui panjang dan lebar retakan. Filter Gabor untuk menemukan retakan mayor dan minor pada struktur beton. Langkah-langkah ekstraksi fitur yang dirancang khusus digunakan untuk menentukan kerusakan. Metode ini juga mengidentifikasi retakan mikro tipis. Struktur beton yang terkena dampak kebakaran memiliki retakan mikro kecil yang dapat dideteksi sebagai noise. Retakan semacam itu terlewatkan oleh banyak model visi komputer karena memerlukan langkah ekstraksi fitur khusus.

Teknik Pembelajaran Mesin (ML)/Pembelajaran Mendalam (DL)

Mengikuti teknik visi komputer, teknik berbasis ML juga digunakan untuk menemukan retakan pada struktur beton. Teknik ML tradisional biasanya memiliki lima tahap, yaitu: pengumpulan citra, pra-pemrosesan, ekstraksi fitur, deteksi kerusakan, dan klasifikasi. Teknik pra-pemrosesan awal merupakan teknik deteksi dasar yang digabungkan dengan metode ML.

Tahap ekstraksi fitur dan deteksi kerusakan digunakan dengan berbagai algoritma optimasi dan jaringan saraf tiruan.

Untuk memproses dataset masukan yang besar, metode berbasis ML diadopsi untuk mengklasifikasikan retakan pada beton. Teknik Support Vector Machine (SVM) dan Extreme Learning Machine (ELM) telah diterapkan untuk mendeteksi retakan dari citra masukan. Proses ekstraksi fitur dilakukan dengan metode ini sebagai langkah utama untuk mempelajari citra masukan. Jika lebih banyak karakteristik perlu diekstraksi, maka teknik reduksi fitur diterapkan untuk menemukan atribut yang optimal. Analisis Komponen Utama (PCA) digunakan untuk melakukan seleksi fitur, dan dengan demikian menghasilkan set fitur yang informatif. Atribut optimal diberikan kepada pengklasifikasi untuk mendeteksi retakan secara akurat. Selain itu, K tetangga terdekat (KNN), Jaringan Syaraf Tiruan (JST), logika fuzzy dengan SVM, algoritma genetika dengan SVM adalah berbagai jenis pengklasifikasi yang digunakan untuk mendeteksi retakan dari masukan.

Metode pengenalan pola tradisional terlibat dalam pra-pemrosesan, ekstraksi fitur, segmentasi, klasifikasi, dan pengenalan. Banyak algoritma diperkenalkan di setiap langkah. Namun, karena struktur masukan yang kompleks, sulit untuk menggunakan alur proses tradisional. Langkah ekstraksi fitur sulit karena karakteristik tingkat tinggi yang terkait dengan lokasi kerusakan diberikan oleh pengguna. Karena ditentukan oleh pengguna akhir, hal ini akan mengurangi akurasi keseluruhan proses deteksi. Hal ini diatasi dengan teknik DL yang dapat melakukan langkah ekstraksi fitur otomatis dan menangani input dalam jumlah besar.

DL merupakan alat baru dalam AI yang telah memungkinkan kemajuan signifikan dalam bidang pengenalan pola baru-baru ini. Performa teknik ini baik dibandingkan dengan teknik ML. Metode-metode ini didasarkan pada DL dan telah diterapkan di berbagai bidang penelitian seperti deteksi objek, segmentasi citra medis, deteksi kerusakan, klasifikasi tutupan lahan, dan deteksi penyakit dalam pertanian presisi. Terlepas dari bidangnya, teknik DL memberikan hasil yang lebih baik dalam proses otomatis. Baru-baru ini, para peneliti di bidang penginderaan jauh dan geologi telah menggunakan prosedur DL secara efektif.

Sistem perangkat lunak CrackNet yang terdiri dari arsitektur CNN dengan lima lapisan. Metode deteksi retakan per piksel dilakukan untuk permukaan aspal. Arsitektur ini secara efisien mendeteksi retakan, tetapi waktu komputasinya tinggi untuk deteksi. Retakan tipe garis rambut tidak terdeteksi dengan baik oleh metode ini. Untuk mengatasi tantangan ini, CrackNet II, telah dikembangkan untuk mengurangi waktu komputasi dan noise yang terkait dengan permukaan aspal. Waktu pelatihan dikurangi dengan menyempurnakan parameter model arsitektur.

Meskipun beberapa metode ML dan DL tersedia untuk deteksi kerusakan beton, teknik yang terkait dengan beton yang terkena kebakaran masih kurang mendapat perhatian. Salah satu alasan utama hal ini adalah dibutuhkannya waktu dan upaya yang jauh lebih besar untuk mengukur dan mengidentifikasi kerusakan akibat kebakaran.

Pada bab ini mengusulkan metodologi deteksi retak otomatis berbasis DL untuk beton yang terdampak kebakaran. Model CNN yang telah disesuaikan telah digunakan untuk mendeteksi kerusakan dengan mengkuantifikasi pembentukan retak. Selain itu, analisis

korelasi numerik pada beton yang terdampak kebakaran juga diberikan secara mendalam. Metode deteksi retak otomatis diusulkan dan diperiksa dengan parameter retak yang diperoleh dari pengamatan optik. Uji kuat tekan juga dilakukan untuk mengukur kekuatan maksimum beton yang terbakar dan mengkuantifikasi kehilangan kapasitasnya.

Sampel Beton

Dalam pekerjaan ini, sampel beton berukuran 150 × 150 × 150 mm disiapkan dan diuji dalam tungku listrik seperti yang dibahas di bawah ini. Untuk setiap tingkat suhu (S-60, S-120, S-180, dan S-240), 20 sampel dipertimbangkan untuk pengujian. Sampel-sampel ini menyediakan data yang menjadi dasar pengembangan teknik ML/DL.

6.3 MATERIAL

Semen Portland Biasa (OPC) dengan mutu 53 yang memenuhi standar IS: 12269-2013 digunakan dalam penelitian ini. Semen ini dibeli dari satu sumber untuk menjaga kualitas yang digunakan untuk sampel coran. Konsistensi standar semen dievaluasi sesuai dengan IS: 4031—1988. Kuat tekan sampel yang terbuat dari semen ditentukan sesuai dengan IS: 4031—1988 untuk memastikan mutu kekuatannya. Berat jenis semen adalah 3,15.

Agregat Kasar

Dalam penelitian ini, batu granit pecah digunakan sebagai agregat kasar dengan berat normal. Agregat kasar yang digunakan adalah granit pecah mekanis yang diambil dari kota Coimbatore, India. Berat jenis agregat kasar adalah 2,96 dan memenuhi standar IS 383-2016.

Agregat Halus

Agregat halus yang digunakan dalam penelitian ini adalah pasir sungai alami yang dibawa dari Dasar Sungai Cauvery, Karur, sesuai dengan IS: 383-2016. Berat jenis pasir ditentukan sesuai dengan IS: 2386(PIII)-1963. Berat jenisnya adalah 2,70. Analisis saringan dilakukan untuk memastikan gradasinya berada di Zona II. Berat jenis agregat halus yang digunakan adalah 1620 kg/m³.

Gradasi agregat kasar dan halus berperan penting dalam kemampuan kerja dan pengembangan pasta. Gradasi ukuran partikel penting untuk karakterisasi agregat, karena efek pengemasan partikel menghasilkan pengurangan rongga. Hal ini, pada gilirannya, memengaruhi kebutuhan air dan kebutuhan kandungan bubuk dalam beton.

Air merupakan bahan utama yang digunakan untuk hidrasi semen. Air minum digunakan untuk campuran beton. Air yang digunakan untuk percobaan memenuhi standar IS 456:2000.

6.4 PENGUJIAN SPESIMEN PADA SUHU TINGGI

Spesimen beton disimpan dalam tangki curing selama 28 hari untuk mencapai kekuatan maksimum. Spesimen referensi kering diuji di laboratorium sebelum dipanaskan. Spesimen yang tersisa dipanaskan dalam tungku listrik yang dikontrol komputer mengikuti kurva api standar, dengan waktu pemaparan berkisar antara 60 hingga 240 menit.


Spesimen beton dikeringkan selama 24 jam dalam oven pada suhu 60°C sebelum dipanaskan dalam tungku pada waktu pemaparan yang berbeda sesuai dengan kurva waktu-

suhu api standar ISO 834-1:1999. Spesimen ditempatkan di dalam tungku melalui boogie dan suhu diatur sesuai waktu yang dibutuhkan. Tungku terdiri dari kumparan di keempat sisi yang memanaskan spesimen melalui radiasi ketika suhu target diatur. Tungku berukuran 700 × 400 × 400 mm dengan daya 100 kW ditunjukkan pada Gambar 6.4. Tungku ini memiliki dua tampilan: (1) tampilan nilai yang ditetapkan, yang menunjukkan suhu gas yang akan dipanaskan pada waktu tertentu, dan (2) tampilan nilai program yang menampilkan suhu yang dicapai dalam kumparan pada waktu tertentu.


Setelah suhu ditetapkan, kumparan akan memanaskan spesimen hingga waktu yang ditentukan. Setelah suhu yang ditentukan tercapai, tungku akan berhenti. Spesimen dikeluarkan dari tungku dan ditempatkan di area tertutup untuk pendinginan udara alami. Suhu operasi maksimum tungku adalah 1200°C. Tungku ini dilengkapi dengan pengontrol mikro yang dapat diprogram untuk mengontrol suhu sesuai kurva suhu standar yang diberikan pada Persamaan 6.1.

$$T - T_0 = 345 \log_{10} (8t + 1) \quad (6.1)$$

di mana: T—Suhu tungku pada waktu t (derajat Celsius), T₀—Suhu tungku awal (derajat Celsius), t—Waktu (menit). Gambar 6.2 menampilkan kurva Waktu-Suhu Api Standar ISO 834. Gambar 6.3 memberikan siklus pemanasan pendinginan pendinginan udara alami yang digunakan untuk investigasi, seperti yang diperoleh dari sampel eksperimen. Kurva api ISO yang khas ini dipilih karena laju pemanasan cukup tinggi yang penting untuk beton dan beberapa peneliti telah mengadopsi kurva ini untuk penelitian mereka. Suhu spesimen dipantau oleh termokopel yang dipasang di berbagai titik. Termokopel yang terhubung ke akuisisi data otomatis digunakan. Selama percobaan, suhu tungku dan permukaan spesimen dicatat. Gambar 6.4 menunjukkan posisi termokopel yang digunakan untuk mengukur suhu spesimen beton.



Gambar 6.2: Siklus pemanasan dan pendinginan.



Gambar 6.3: Kurva suhu waktu.



Gambar 6.4: Uji suhu tinggi.


Kuat Tekan

Sebuah mesin uji tekan digital berkapasitas 200 ton yang mampu memberikan beban tanpa guncangan digunakan untuk memberikan beban secara terus-menerus dengan laju sekitar $140 \text{ kg/cm}^2/\text{menit}$ hingga mencapai titik kegagalan. Benda uji kubus berukuran $150 \times 150 \text{ mm}$ digunakan untuk menguji kuat tekan beton seperti yang ditunjukkan pada Gambar 6.5.

Sebagaimana telah dijelaskan sebelumnya, benda uji beton dengan berbagai tingkat kekuatan dicor dan diuji dengan durasi pemanasan yang berbeda-beda sesuai dengan kurva api standar. Minimal tiga sampel dipertimbangkan untuk setiap tingkat kekuatan dan durasi pemanasan guna mengonfirmasi hasil pengujian.



Gambar 6.5: Uji kuat tekan pada kubus beton berukuran 150 × 150 × 150.



Gambar 6.6: Kuat tekan sisa sampel beton yang terpapar api.

Kuat Tekan

Gambar 6.6 menunjukkan kuat tekan sisa campuran beton mutu M50 yang terpapar berbagai durasi pemanasan. Setelah paparan selama 60 menit (maks. 925°C), kuat tekan sisa adalah 73,5% dari kekuatan awal campuran mutu M50, dengan kekuatan sisa 35,5% pada 120 menit. Pada waktu paparan 180 menit, spesimen menunjukkan penurunan kekuatan yang parah dan memiliki kekuatan sisa 22% dari kuat tekan awal.

Pada durasi pemanasan 240 menit (1133°C), kekuatan sisa ditemukan sebesar 11,3%. Penurunan kekuatan yang parah terjadi karena rusaknya gel CSH dalam struktur mikro pasta. Selain itu, terjadi transformasi struktur kristal agregat. Gaya internal yang dihasilkan oleh pemanasan yang tidak merata dan pemuai uap juga dapat menghasilkan tegangan signifikan yang meningkatkan kerusakan.

6.5 METODOLOGI UNTUK DETEKSI RETAK

Akuisisi dan Prapemrosesan Data Citra

Setelah percobaan uji api, citra spesimen yang rusak akibat kebakaran ditangkap oleh kamera digital beresolusi tinggi. Kamera dengan dudukan dipasang secara permanen di dekat tungku pemanas (Gambar 6.7). Spesimen didinginkan dengan udara alami sebelum mengambil citra. Karena perambatan retak meningkat selama fase pendinginan, citra diambil setelah spesimen mencapai suhu ruangan. Retakan terbentuk karena pengaruh suhu tinggi sehingga disebut sebagai retakan termal. Namun, sifat retakan dapat berubah berdasarkan suhu, durasi pemanasan, dan jenis material beton, seperti yang telah dibahas sebelumnya.



Gambar 6.7: Pengaturan akuisisi gambar.

Pengaturan akuisisi gambar terdiri dari kamera Canon SX510 HS untuk mengambil foto dengan penstabil gambar optik (IS) cerdas untuk foto yang tajam. Kamera ini memiliki zoom optik 30x dengan lensa lebar 24 mm dalam bodi mini. Kamera ini juga dilengkapi Sistem Zoom Plus HS 60x dengan CMOS 12,1 Megapiksel yang dilengkapi fasilitas DIGIC 4 dan dapat menghasilkan gambar berkualitas tinggi bahkan dalam kondisi minim cahaya.

Pembesaran zoom membantu perangkat untuk melacak subjek yang jauh dengan kejelasan yang baik. Beberapa gambar diambil berulang kali dengan posisi statis spesimen beton, dan gambar terbaik digunakan untuk analisis. Gambar 6.8 menunjukkan kerangka kerja yang diusulkan untuk mendeteksi retakan termal pada beton struktural.

Metode CNN yang Disesuaikan

Dalam metode deteksi retakan otomatis yang diusulkan, arsitektur CNN yang disesuaikan dibangun dari awal dengan menyesuaikan berbagai hiperparameter, yaitu jumlah lapisan konvolusi, lapisan yang terhubung penuh, langkah, jenis pengumpulan, lokasi pengumpulan, jumlah filter, dan ukuran filter. Hiperparameter dipilih hanya dengan metode coba-coba. Tidak ada metode perhitungan matematis yang tepat untuk menetapkan hiperparameter untuk dataset tertentu. Gambar 6.9 menunjukkan arsitektur CNN yang dikustomisasi untuk penelitian yang diusulkan. Arsitektur ini terdiri dari 5 lapisan konvolusi, 3 lapisan penyatuan, 3 aktivasi, 1 lapisan soft-max, dan 2 lapisan terhubung penuh. Semua

lapisan ini digunakan untuk meningkatkan kinerja jaringan dengan melakukan ekstraksi fitur, reduksi dimensionalitas, dan menggabungkan non-linearitas.

Lapisan konvolusi digunakan untuk meningkatkan sifat invariansi spasial untuk mengekstrak semua fitur penting dari citra masukan. Arsitektur CNN sangat bergantung pada fitur spasial masukan. Jika citra masukan didominasi oleh sparse, maka laju pembelajaran jaringan akan menurun secara signifikan. Dalam model ini, pengoptimal Adam digunakan sebagai laju pembelajaran adaptif untuk menangani data sparse. Pengoptimal ini menangani masalah gradien menghilang dibandingkan dengan pengoptimal lain seperti RMSprop dan Adadelta.

Citra masukan diubah ukurannya menjadi 224×224 dan diteruskan ke lapisan pertama. Citra masukan direpresentasikan sebagai $a \times b \times c$. Citra ini akan diteruskan ke lapisan konvolusi dan lapisan penggabungan untuk mengurangi ukuran spasial. 'a', 'b', dan 'c' merepresentasikan tinggi, bobot, dan jumlah kanal warna citra masukan. Setelah diteruskan ke lapisan-lapisan yang berbeda, vektor fitur akhir diperoleh melalui lapisan terhubung penuh (fully-connected layer). Deteksi retakan akhir diperoleh dari lapisan yang terhubung penuh (fully-attached layer). Awalnya, lapisan konvolusi digunakan untuk menemukan fitur dengan mengidentifikasi kemungkinan koneksi dari sampel data masukan yang diambil dari lapisan masukan menggunakan persamaan hubungan berikut (6.2):

$$X = \sum (Input_{d \times d} + Weight_{e \times e}) + F \quad (6.2)$$

di mana X adalah vektor fitur. $Input_{d \times d}$ merepresentasikan medan reseptif input tempat operasi konvolusi dilakukan. $Weight_e$ dan F adalah bobot filter, ukuran kernel, dan ukuran filter lapisan konvolusi. Vektor fitur dihitung dengan melakukan konvolusi pada piksel gambar dan menjumlahkan nilai-nilai piksel tersebut. Sehubungan dengan kernel konvolusi, peta fitur divariasikan. Vektor fitur akhir diberikan ke lapisan aktivasi ReLU, yang membuat nilai non-negatif menjadi nol, dengan mengeksekusi operasi per elemen.

Hal ini dilakukan untuk nilai output dari lapisan konvolusi. Fungsi aktivasi ReLU terutama digunakan di sebagian besar arsitektur DL karena kemampuan komputasinya yang lebih tinggi. Sigmoid, tanh, dan swish adalah fungsi aktivasi berbeda yang tersedia. Lapisan ini memastikan penggunaan peta fitur yang diambil dari lapisan konvolusi dengan lebih baik dengan menggabungkan non-linearitas. Persamaan (6.3) termasuk dalam lapisan aktivasi.

$$\vartheta(J) = \max(0, J) \quad (6.3)$$

di mana 'J' menunjukkan elemen vektor masukan.

Lapisan penggabungan membagi data peta fitur menjadi kernel yang tidak tumpang tindih. Nilai maksimum setiap kernel diteruskan ke lapisan berikutnya. Dua rangkaian operasi dilakukan oleh lapisan penggabungan maksimum. Down-sampling data masuk dan mengurangi dimensionalitas merupakan rangkaian operasi pertama.

Hal ini mengurangi parameter model dan dengan demikian mengurangi waktu komputasi dan merupakan rangkaian operasi kedua yang dilakukan oleh lapisan penggabungan. Lapisan terhubung penuh adalah lapisan keluaran yang melakukan inferensi logis. Dalam penelitian ini, lapisan terhubung penuh mengubah vektor tiga dimensi menjadi vektor satu dimensi dan melakukan operasi konvolusi penuh. Keluaran dari lapisan terhubung penuh diberikan oleh Persamaan (6.4).


$$K_{n_o \times 1} = K_{n_o \times n_i} J_{n_i \times 1} \cdot B_{n_o \times 1} \quad (6.4)$$

di mana n_o dan n_i merepresentasikan ukuran vektor masukan dan keluaran, K merepresentasikan keluaran lapisan terhubung penuh, W dan B adalah matriks bobot dan bias. Gambar 6.10 menunjukkan contoh keluaran lapisan aktivasi dan penggabungan.

Fungsi kerugian digunakan untuk mengevaluasi efisiensi model yang diusulkan. Fungsi ini digunakan untuk mengevaluasi deviasi antara nilai aktual dan nilai prediksi. Untuk masukan yang besar, jaringan membuat keputusan berdasarkan masukan tersebut. Pada saat proses pembelajaran, fungsi kerugian terus diubah hingga mencapai kecocokan terbaik sehubungan dengan minimisasi kesalahan. Fungsi softmax atau fungsi entropi silang digunakan untuk menemukan selisih antara nilai aktual dan nilai prediksi seperti yang ditunjukkan oleh Persamaan (6.5).

$$LF_{SMMax} = N^{-1} \sum_{i=1}^N \log \left(\frac{e^{a_n}}{\sum e^{a_k}} \right) a \quad (6.5)$$

yang merepresentasikan jumlah total neuron pada lapisan keluaran akhir dan merupakan data masukan.



Gambar 6.10: Contoh keluaran lapisan aktivasi dan penggabungan.


Hiperparameter atau parameter internal jaringan memainkan peran penting dalam menjalankan tugas deteksi secara akurat. Pemilihan pengoptimal yang sesuai penting untuk mendapatkan hasil deteksi akhir. Prosedur optimasi digunakan untuk meminimalkan fungsi kerugian dan memperbarui hiperparameter.

Pelatihan dan Pengujian


Model kustom yang diusulkan diimplementasikan menggunakan MATLAB®, prosesor 2,90 GHz dengan kartu GPU 12 GB pada NVIDIA GTX1050. Performa metode deteksi retakan otomatis yang diusulkan diperingkat berdasarkan ukuran masukan, hiperparameter jaringan, dan laju konvergensi. Enam ribu citra digunakan dari eksperimen. Citra pelatihan dan pengujian diambil dengan rasio 80:20. Citra pelatihan dan pengujian tidak tumpang tindih.

6.6 DETEKSI KERUSAKAN DARI METODE CNN

Bagian ini membahas hasil eksperimen metode yang diusulkan dan validasinya terkait observasi optik. Gambar 6.11 menunjukkan hasil deteksi kerusakan dari metode CNN kustom yang diusulkan. Citra pada baris pertama mewakili citra retakan asli yang diselidiki dengan paparan waktu pembakaran standar yang berbeda. Baris kedua menunjukkan hasil model CNN yang diusulkan. Kerusakan beton yang terdampak kebakaran seperti retakan permukaan, pori-pori, dan tepi yang terisolasi direpresentasikan dalam garis putih. Hal ini dengan jelas menunjukkan bahwa kerusakan mikro dan makro terdeteksi secara akurat oleh metode yang diusulkan.



Gambar 6.11: Hasil deteksi retak dengan gambar atas menunjukkan sampel beton dan gambar bawah menunjukkan hasil dari model CNN.



Gambar 6.12: Hasil deteksi retak dari AutoCAD.

Tabel 6.1: Hasil kuantitatif sifat retak.

ID spesimen	(x) Jumlah Total Pixel yang Diidentifikasi sebagai Kerusakan oleh CNN yang Diusulkan (pixel)	(y) Total Panjang Retak yang Diidentifikasi oleh AutoCAD (mm)	Rasio (x/y)
S-60	128705	1548	83.14×10^2
S-120	346341	4052	85.47×10^2
S-180	688438	7944	86.66×10^2
S-240	1346451	15142	88.92×10^2

Hasil model CNN kustom yang diusulkan divalidasi dengan melakukan observasi dan pengukuran manual melalui AutoCAD. Contoh hasil analisis AutoCAD ditunjukkan pada Gambar 6.12. Hal ini dengan jelas menunjukkan bahwa hasil metode yang diusulkan sesuai dengan hasil observasi. Perbandingan visual menunjukkan bahwa metode DL lebih akurat dibandingkan dengan hasil AutoCAD. Contoh citra diambil dari durasi pemanasan yang berbeda seperti 1 jam, 2 jam, 3 jam, dan 4 jam. Total kerusakan permukaan dinyatakan dalam piksel dalam metode pembelajaran mendalam yang diusulkan. Dari pengamatan manual yang dilakukan, total kerusakan dinyatakan dalam milimeter panjang retakan. Sifat-sifat panjang retakan dirinci pada Tabel 6.1.

Tabel 6.1 menunjukkan hasil kuantitatif dari metode DL yang diusulkan dan metode observasi optik melalui AutoCAD. Kerusakan dikuantifikasi berdasarkan panjang retakan. Jumlah total piksel yang terkait dengan retakan dinyatakan sebagai ' x '. Total panjang retakan yang diukur dengan observasi optik dinyatakan dalam ' y ' dan diukur dalam milimeter (mm). Kedua hasil kuantitatif ini tidak dapat dibandingkan secara langsung. Lebar retakan bervariasi dari 0,13 mm hingga 1,12 mm. Karena variasi ini, pengukuran lebar retakan secara manual merupakan proses yang memakan waktu.

Menentukan lebar retakan rata-rata juga sulit. Oleh karena itu, perhitungan rasio disediakan. Rasio antara jumlah total piksel retakan, yang diperoleh dari model DL, dan observasi optik dilakukan. Rasio tersebut tampaknya konsisten antar sampel. Menarik untuk dicatat bahwa, pada setiap kategori spesimen, rentang nilainya rendah dengan deviasi yang kecil. Analisis ini menyoroti bahwa metode DL yang diusulkan dapat mendeteksi retakan permukaan pada spesimen beton yang terdampak kebakaran. Jumlah total piksel yang teridentifikasi untuk spesimen S-60 adalah 128.705 dan untuk S-240 adalah 1.346.451. Jumlah total piksel retakan meningkat seiring dengan durasi pemanasan spesimen.


ID spesimen mewakili durasi pemanasan seperti 60 menit, 120 menit, 180 menit, dan 240 menit. Dengan mempertimbangkan peningkatan jumlah total piksel, sampel dengan peningkatan waktu paparan kebakaran mengalami peningkatan retak dan kerusakan, sebagaimana yang diharapkan dan konsisten dengan uji kekuatan pasca-kebakaran. Oleh karena itu, metode DL secara akurat mendeteksi kerusakan dari citra masukan.

Analisis Korelasi


Bagian ini membahas perilaku termal-struktural spesimen beton yang mengalami paparan api standar. Analisis korelasi deteksi retak dapat digunakan sebagai salah satu indikator evaluasi kerusakan untuk menilai kerusakan akibat kebakaran pada struktur beton.

Alasan utamanya adalah retakan merupakan bukti tegangan dan regangan yang tinggi, serta penurunan sifat material, pada beton yang terdampak kebakaran.

Seiring dengan peningkatan suhu, hal ini menyebabkan retakan pada struktur akibat perambatan panas dan termal yang diinduksi. Analisis korelasi antara retakan dan durasi pemanasan diberikan pada Gambar 6.13 dan 6.14. Panjang retakan yang diukur dengan metode DL yang diusulkan dan melalui pengamatan optik disorot.



Gambar 6.13: Korelasi antara suhu dan panjang retak (Observasi optik).



Gambar 6.14: Korelasi antara suhu dan panjang retak (Metode Pembelajaran Mendalam).

Seiring meningkatnya suhu dan waktu paparan api, panjang retakan juga bertambah. Pengukuran panjang melalui observasi optik dan metode DL dengan jelas menunjukkan perubahan panjang retakan dengan waktu paparan api standar, dan hal ini tampaknya mengikuti tren parabola. Jumlah total piksel yang terdeteksi sebagai kerusakan oleh metode DL yang diusulkan menunjukkan korelasi yang baik dengan tingkat paparan suhu.

6.7 KESIMPULAN

Studi ini menyelidiki deteksi otomatis retakan termal pada struktur beton yang terdampak kebakaran. Arsitektur CNN DL yang dikustomisasi diusulkan untuk mendeteksi retakan tersebut. Deteksi otomatis retakan termal divalidasi berdasarkan observasi optik. Hasil kuantitatif dari metode DL yang dikustomisasi yang diusulkan menunjukkan kesesuaian yang baik dengan hasil pengukuran observasi optik. Analisis korelasi numerik juga menunjukkan kesesuaian yang dapat diterima.

Dari studi ini disimpulkan bahwa perambatan kerusakan sepenuhnya bergantung pada waktu paparan api, seperti yang diharapkan. Seiring meningkatnya suhu, kerusakan meningkat akibat degradasi material dan tegangan yang diinduksi dari gradien suhu. Keterbatasan utama dari penelitian ini adalah tidak dapat menentukan kedalaman retakan. Metodologi yang diusulkan akan berguna untuk mengotomatiskan kuantifikasi kerusakan akibat kebakaran, baik dalam pekerjaan eksperimental maupun pada bangunan nyata. Penelitian lebih lanjut diperlukan untuk melatih algoritma agar dapat beradaptasi dengan berbagai skenario dan penyelesaian beton. Jika terdapat endapan jelaga pada sampel beton, metode ini kemungkinan akan kurang akurat.

BAB 7

KECERDASAN BUATAN DALAM INFRASTRUKTUR SIPIL

7.1 PENDAHULUAN

Dengan maraknya data dalam jumlah besar di berbagai bidang, digitalisasi telah muncul sebagai proses yang berkaitan dengan transformasi informasi ke dalam format digital yang seringkali dapat dibaca oleh komputer. Digitalisasi telah mendorong meningkatnya minat terhadap ilmu data dan analitik data. Ilmu data adalah bidang studi multidisiplin yang mengandalkan perangkat, algoritma, serta pengetahuan statistik dan matematika untuk menemukan wawasan dari data mentah.

Di sisi lain, analitik data adalah salah satu subbidang ilmu data dan didefinisikan sebagai "proses memeriksa, membersihkan, mentransformasi, dan memodelkan Big Data untuk menemukan dan mengomunikasikan informasi dan pola yang bermanfaat, menyarankan kesimpulan, dan mendukung pengambilan keputusan". Kecerdasan buatan (AI) telah menawarkan peluang yang belum pernah ada sebelumnya untuk mengambil dan mengungkap pola, tren, hubungan, dan pengetahuan yang luar biasa dari kumpulan data besar.

Kecerdasan buatan didefinisikan sebagai "studi dan implementasi teknik yang memungkinkan tindakan yang membutuhkan kecerdasan manusia, untuk dilakukan pada perangkat komputasi". Selama beberapa dekade, AI telah diterapkan untuk mengatasi tantangan dan memberikan solusi di berbagai bidang penelitian dan domain aplikasi. Sehubungan dengan itu, tujuan bab ini adalah untuk menawarkan pengantar tentang metode, prinsip, dan aplikasi AI yang fundamental dan esensial. Bab ini juga memberikan definisi terkait AI dan menyajikan algoritma terkait yang paling banyak digunakan. Terakhir, bab ini berfokus pada penelitian AI terkini dengan pertimbangan khusus pada tiga domain aplikasi berikut: infrastruktur sipil, rekayasa dan manajemen konstruksi, serta keselamatan.

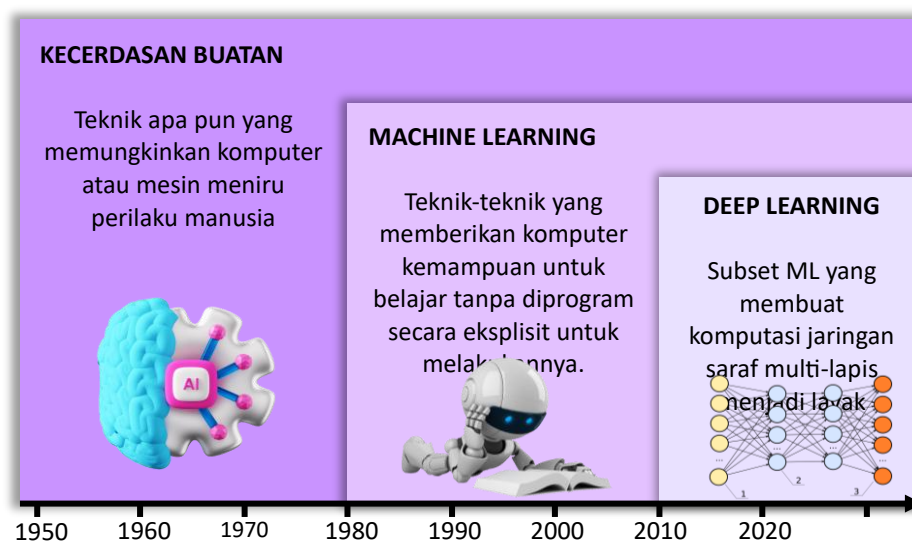
7.2 KATEGORI KECERDASAN BUATAN

Kecerdasan buatan mencakup berbagai bidang; salah satunya adalah pembelajaran mesin (ML), yang merupakan "subbidang kecerdasan buatan yang mempelajari bagaimana komputer dapat belajar. Bidang ini sangat bergantung pada teknik dan teori dari statistika, optimasi, [dan] algoritma". Faktanya, teknik AI dan ML merupakan salah satu katalisator utama di balik revolusi ilmu komputasi. Selain itu, subset dari ML adalah pembelajaran mendalam (DL) yang didefinisikan sebagai "sejenis metode pembelajaran representasi di mana arsitektur jaringan saraf multilayer yang kompleks mempelajari representasi data secara otomatis dengan mengubah informasi masukan menjadi beberapa tingkat abstraksi". Gambar 7.1 memberikan ikhtisar dan ringkasan perbedaan antara AI, ML, dan DL serta tanggal atau periode terkait di mana masing-masing teknik ini mendapatkan perhatian dan penggunaan yang cukup besar.

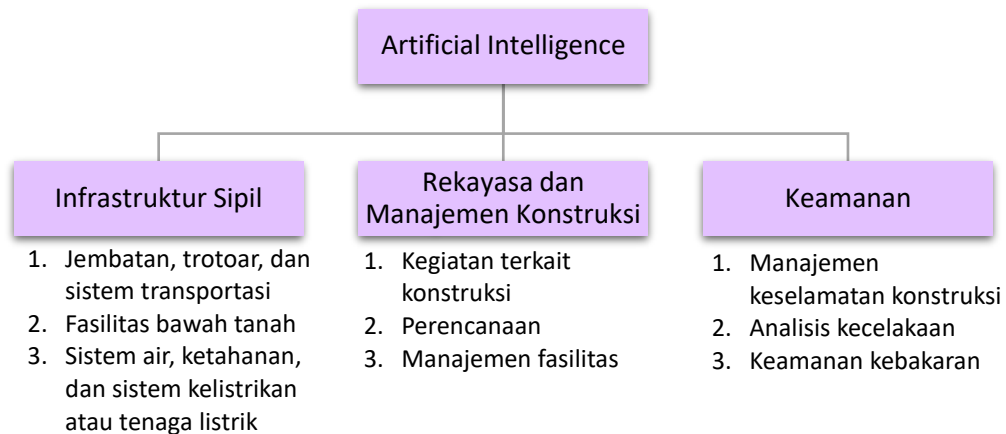
Teknik atau algoritma pembelajaran mesin dapat dibagi menjadi tiga kategori utama: pembelajaran terawasi, pembelajaran tak terawasi, dan pembelajaran penguatan. Dengan kata sederhana, pembelajaran terawasi adalah "mode pembelajaran mesin untuk mempelajari tugas yang memetakan data masukan menjadi data keluaran berdasarkan pasangan masukan-keluaran sampel". Di sisi lain, pembelajaran tanpa pengawasan didefinisikan sebagai "pelatihan algoritma kecerdasan buatan (AI) menggunakan informasi yang tidak diklasifikasikan maupun diberi label dan memungkinkan algoritma untuk bertindak berdasarkan informasi tersebut tanpa panduan".

Sedangkan untuk pembelajaran penguatan, dapat didefinisikan sebagai "cabang pembelajaran mesin yang berkaitan dengan penggunaan pengalaman yang diperoleh melalui interaksi dengan dunia dan umpan balik evaluatif untuk meningkatkan kemampuan sistem dalam membuat keputusan perilaku". Perlu disebutkan bahwa berbagai varian teknik pembelajaran telah berkembang, seperti pembelajaran semi-supervised, antara lain. Sehubungan dengan hal tersebut, pembelajaran semi-supervised menggabungkan pembelajaran tersupervised dan tak tersupervised, dan didefinisikan sebagai "paradigma pembelajaran yang berkaitan dengan studi tentang bagaimana komputer dan sistem alami seperti manusia belajar dengan adanya data berlabel maupun tak berlabel".

Lebih lanjut, pembelajaran tersupervised dapat digunakan baik untuk aplikasi klasifikasi (yaitu, di mana variabel keluaran bersifat kategorikal atau kelas) maupun untuk tujuan regresi (yaitu, di mana variabel keluaran bersifat numerik). Karena mustahil untuk mencantumkan semua algoritma atau teknik yang digunakan dalam pembelajaran tersupervised maupun tak tersupervised, bab ini mencantumkan algoritma yang umum digunakan. Sehubungan dengan hal tersebut, menurut ProjectPro (2021), berikut ini adalah algoritma pembelajaran mesin tradisional yang umum: jaringan saraf tiruan, pengklasifikasi Bayes naif, pengelompokan k-means, mesin vektor pendukung, algoritma Apriori, regresi linier, regresi logistik, pohon keputusan, hutan acak, dan tetangga terdekat.



Gambar 7.1: Kecerdasan buatan, pembelajaran mesin, dan pembelajaran mendalam.



Gambar 7.2: Fokus bab.

Namun demikian, perlu disebutkan bahwa bab ini tidak dimaksudkan sebagai daftar lengkap semua algoritma AI karena bab ini tidak bertujuan untuk memberikan daftar lengkap semua teknik dan algoritma AI yang memungkinkan atau menjelaskan cara kerja setiap algoritma. Sebaliknya, terdapat banyak buku unggulan yang dapat dirujuk oleh pembaca untuk mendapatkan daftar algoritma AI yang lebih komprehensif dan mempelajari sains, matematika, dan statistik di balik setiap teknik.

Bab ini mengulas penelitian terbaru dalam AI dengan pertimbangan khusus pada tiga domain: infrastruktur sipil, rekayasa dan manajemen konstruksi, serta keselamatan. Di bawah masing-masing domain ini, tinjauan tiga aplikasi utama disajikan seperti yang ditunjukkan pada Gambar 7.2. Perlu disebutkan bahwa bab ini berfokus pada tinjauan penelitian dan pengetahuan terkini (yaitu, 2010–2021) tentang penggunaan teknik dan algoritma AI dalam tiga domain yang telah disebutkan sebelumnya.

7.3 PENELITIAN TERKINI (STATE-OF-THE-ART) DALAM BIDANG KECERDASAN BUATAN

Bagian ini membahas perkembangan mutakhir dalam bidang kecerdasan buatan (Artificial Intelligence/AI) dengan fokus pada tiga domain utama, yaitu sistem infrastruktur sipil, rekayasa dan manajemen konstruksi, serta keselamatan kerja. Dalam sistem infrastruktur sipil, AI dimanfaatkan untuk memantau, menganalisis, dan memprediksi kinerja jangka panjang struktur-struktur penting seperti jembatan, gedung bertingkat, bendungan, maupun jalan raya. Teknologi sensor pintar yang terintegrasi dengan algoritma pembelajaran mesin mampu mendeteksi keretakan mikro, mengukur deformasi, dan memprediksi umur layanan struktur sehingga perawatan dapat dilakukan lebih tepat waktu. Hal ini menjadi bagian penting dari *Structural Health Monitoring (SHM)* yang semakin berkembang seiring meningkatnya kebutuhan akan infrastruktur yang andal dan berumur panjang.

Di bidang rekayasa dan manajemen konstruksi, kecerdasan buatan banyak digunakan untuk mengoptimalkan perencanaan proyek, manajemen sumber daya, serta pengendalian biaya dan waktu. Algoritma berbasis AI, seperti *genetic algorithms* maupun *reinforcement learning*, dapat membantu menyusun jadwal kerja yang lebih efisien dengan mempertimbangkan keterbatasan tenaga kerja, material, hingga faktor eksternal seperti

kondisi cuaca. Selain itu, pemanfaatan *computer vision* berbasis AI juga semakin populer dalam memantau progres pembangunan secara real-time melalui citra dan video yang diambil dari drone maupun kamera lapangan, sehingga pengawasan proyek menjadi lebih akurat dan transparan.

Sementara itu, dalam aspek keselamatan kerja, AI berperan besar dalam mendeteksi potensi bahaya sekaligus mencegah kecelakaan. Teknologi visi komputer mampu mengenali perilaku berisiko pekerja, misalnya ketika tidak mengenakan helm atau alat pelindung diri sesuai standar. Lebih jauh, sistem prediksi berbasis AI juga dapat menganalisis data kecelakaan dari masa lalu untuk mengidentifikasi pola risiko yang sering terjadi, sehingga langkah-langkah pencegahan bisa dirancang lebih efektif. Dengan penerapan ini, lingkungan kerja menjadi lebih aman, angka kecelakaan dapat ditekan, dan produktivitas tenaga kerja meningkat.

Secara keseluruhan, penelitian terkini menunjukkan bahwa kecerdasan buatan tidak lagi sebatas konsep teoretis, tetapi telah diaplikasikan secara nyata dalam berbagai aspek dunia teknik sipil dan konstruksi. Kehadiran AI membawa dampak signifikan dalam meningkatkan efisiensi biaya, mempercepat proses pembangunan, memastikan kualitas desain yang lebih baik, sekaligus menciptakan sistem kerja yang lebih aman dan berkelanjutan.

Aplikasi dalam Sistem Infrastruktur Sipil

AI telah digunakan dalam berbagai aplikasi infrastruktur sipil. Aplikasi ini terutama meliputi (1) jembatan, perkerasan jalan, dan sistem transportasi; (2) fasilitas bawah tanah; dan (3) sistem air, ketahanan, serta sistem kelistrikan atau tenaga.

Jembatan, Perkerasan Jalan, dan Sistem Transportasi

Subbagian ini menyajikan ringkasan riset terkini di berbagai aplikasi infrastruktur terkait jembatan, perkerasan jalan, dan sistem transportasi. Sehubungan dengan hal tersebut, tinjauan mengenai pengetahuan dan penggunaan berbagai teknik AI terkini dan terbaru disajikan. Jembatan, perkerasan jalan, dan transportasi merupakan sistem infrastruktur terpenting karena keduanya membangun kebutuhan dan layanan esensial untuk mempertahankan masyarakat modern dan memberikan keunggulan dalam ekonomi global. Berbagai aplikasi teknik AI yang berbeda telah dilakukan untuk mempelajari berbagai karakteristik jembatan, perkerasan, dan transportasi. Dimulai dengan jembatan, DL (jaringan saraf tiruan umpan maju dalam dan kerangka kerja TensorFlow) digunakan untuk menilai kerentanan jembatan terhadap banjir dengan mengusulkan metode probabilistik berbasis simulasi untuk menetapkan permukaan kerapuhan jembatan yang bervariasi terhadap waktu dalam kondisi bahaya banjir. Selain itu, visi komputer digunakan untuk penilaian risiko jembatan dengan memperoleh informasi topografi yang digunakan untuk simulasi situasi aliran yang kompleks.

Selain itu, kondisi kerusakan jembatan dinilai menggunakan teknik ML (misalnya, jaringan saraf tiruan dan k-nearest neighbor) dengan mengembangkan sistem manajemen aset infrastruktur jembatan untuk mengevaluasi dan memprediksi kondisi dek. Aplikasi jembatan lainnya adalah dengan menggunakan faktorisasi tensor untuk menilai dan memprediksi kinerja jembatan di tingkat jaringan. Selain itu, algoritma genetik digunakan untuk mengusulkan metode/model untuk model pemerataan biaya dek jembatan dengan

menghasilkan beberapa solusi pemeliharaan, perbaikan, dan rehabilitasi. Lebih lanjut, jaringan saraf Elman digunakan untuk memprediksi kerusakan jangka panjang elemen jembatan dan untuk memodelkan kinerjanya.

Sejauh menyangkut kegagalan komponen utama jembatan, beberapa teknik ML (terutama analisis diskriminan kuadratik, tetangga terdekat K, pohon keputusan, hutan acak, Bayes naif, dan jaringan saraf tiruan) digunakan untuk memprediksi mode kegagalan kolom jembatan beton melingkar. Sedangkan untuk keamanan jembatan, mesin vektor pendukung digunakan untuk kedalaman gerusan jembatan dan keamanan dengan mengusulkan model untuk menghitung frekuensi alami jembatan dan menerapkan serangkaian simulasi untuk memeriksa faktor-faktor yang memengaruhi kedalaman gerusan.

Demikian pula, sebuah metode baru diperkenalkan untuk skrining keselamatan dan evaluasi kapasitas beban pada populasi jembatan besar menggunakan decision tree dan random forest. Aplikasi jembatan lainnya mencakup penggunaan regresi vektor pendukung untuk mengembangkan model beban truk fatik stokastik guna mempelajari keandalan fatik jembatan gelagar/dek baja las. Lebih lanjut, penelitian dilakukan untuk menyediakan metode pemodelan dan penilaian respons stokastik jembatan lintas laut di bawah pengaruh sayap dan gelombang berkorelasi menggunakan regresi vektor pendukung dan pengambilan sampel Latin hypercube.

Di sisi lain, banyak teknik AI digunakan dalam berbagai aplikasi terkait perkerasan dan sistem transportasi, seperti jalan raya, jalan raya, dll. Terkait dengan itu, pengklasifikasi vektor pendukung dan jaringan saraf berulang digunakan, dan sebuah model diusulkan yang memprediksi dan mengklasifikasikan kinerja sistem infrastruktur perkerasan. Selain itu, kondisi kerusakan perkerasan dinilai menggunakan pohon keputusan dan pohon yang ditingkatkan gradien dengan memprediksi kerusakan indeks kondisi perkerasan (PCI) selama beberapa rentang tahun. Selain itu, ML (TensorFlow), pembelajaran transfer, dan jaringan saraf dalam (Inception-v3) digunakan untuk mendeteksi, mengevaluasi, dan mengklasifikasikan jumlah debu di jalan kerikil.

Selain itu, kondisi atau kekasaran jalan diukur dan diprediksi menggunakan berbagai teknik ML; terutama, regresi linier multivariat, pohon regresi keputusan, jaringan saraf tiruan, dan hutan acak. Selain itu, metode pembelajaran tanpa pengawasan (seperti peta pengorganisasian mandiri dan peta Kohonen) digunakan untuk mendeteksi retakan jalan dari citra perkerasan dengan fokus pada citra bertekstur tinggi. Sejauh menyangkut perkerasan fleksibel, kinerjanya dikarakterisasi untuk berbagai jalan antarnegara bagian menggunakan regresi parameter tetap, regresi parameter acak, dan jaringan saraf tiruan. Demikian pula, sebuah metode diusulkan untuk kerusakan perkerasan fleksibel terkait perubahan iklim dengan memprediksi perubahan masa pakai infrastruktur menggunakan logika fuzzy. Berbagai teknik optimasi berbasis AI (terutama, algoritma genetika, simulasi anil, dan optimasi pencarian Tabu) telah membuktikan efektivitasnya dalam memprioritaskan proyek jalan yang saling terkait sambil meminimalkan total biaya sistem selama cakrawala perencanaan.

Algoritma genetika juga digunakan untuk mengoptimalkan perencanaan perlindungan sistem infrastruktur transportasi (seperti jaringan jalan raya) yang rentan terhadap bencana

mengingat anggaran terbatas. Aplikasi optimasi lainnya mencakup pengembangan model untuk memilih bagian jalan yang belum diaspal yang optimal untuk perawatan kimia penekan debu dalam anggaran terbatas menggunakan algoritma evolusioner. Penelitian juga dilakukan untuk mendeteksi lubang dan anomali perkerasan jalan menggunakan jaringan saraf tiruan. Jaringan saraf tiruan juga digunakan untuk penilaian kondisi gorong-gorong jalan raya serta untuk menawarkan sistem estimasi biaya untuk proyek rehabilitasi jalan aspal karet.

Selain itu, jaringan Bayesian digunakan untuk mengusulkan pendekatan untuk pemodelan degradasi stokastik yang lebih akurat untuk perkerasan jalan dan untuk mengusulkan strategi inspeksi, pemeliharaan, dan rehabilitasi. Mengenai evaluasi kekasaran perkerasan berdasarkan karakteristik kendaraan, pekerjaan penelitian telah dilakukan untuk memperkirakan profil longitudinal tertimbang (WLP) perkerasan berdasarkan informasi respons kendaraan menggunakan multilayer perceptron, support vector machines, dan random forest serta untuk mengembangkan metode pemrosesan respons kendaraan yang terhubung yang mampu mengevaluasi kondisi kekasaran jalan menggunakan ekstraksi dan pemilihan fitur dan jaringan saraf tiruan.

Fasilitas Bawah Tanah

Subbagian ini memberikan ringkasan penelitian terbaru dalam berbagai aplikasi infrastruktur yang berkaitan dengan fasilitas bawah tanah. Sehubungan dengan hal tersebut, tinjauan pengetahuan dan penggunaan berbagai teknik AI terkini dan terbaru disajikan. Visi komputer dan pembelajaran jarak jauh, yaitu jaringan saraf konvolusional wilayah kaskade (R-CNN), digunakan untuk mengusulkan peralatan deteksi cepat terowongan berbasis kamera perangkat terdapat muatan (CCD) pemindaian area. Aplikasi lain terkait dengan kondisi aset kota di mana logika fuzzy digunakan untuk memeriksa opsi rehabilitasi guna mengkuantifikasi perbaikan kondisi yang diperlukan pada aset kota. Untuk jaringan pipa (misalnya, saluran pembuangan) atau pipa air, regresi geoaditif Bayesian digunakan untuk memeriksa kekritisian komponen dalam sistem air limbah besar.

Selain itu, sebuah metode untuk deteksi anomali otomatis dan lokalisasi kondisi internal saluran pembuangan, menggunakan video inspeksi televisi sirkuit tertutup (CCTV), diusulkan menggunakan transformasi fitur invarian skala (SIFT), mesin vektor pendukung, dan deteksi dan pengenalan teks ujung ke ujung (menggunakan algoritma daerah ekstrem stabil maksimal (MSER) dan jaringan saraf konvolusional dalam). Selain itu, visi komputer dan pemrosesan gambar digunakan untuk deteksi retakan otomatis dalam inspeksi saluran pembuangan berdasarkan gambar CCTV.

Selain itu, prediksi skor kerusakan pipa saluran pembuangan dilakukan menggunakan model regresi geoaditif Bayesian dari serangkaian prediktor yang dikategorikan sebagai data fisik, pemeliharaan, dan lingkungan. Regresi binomial negatif dengan tuner Bayesian digunakan untuk menyajikan metode statistik untuk memodelkan kejadian penyumbatan saluran pembuangan atau probabilitas kegagalan infrastruktur saluran pembuangan. Selain itu, algoritma genetik digunakan untuk mengusulkan metode untuk memeriksa pipa-pipa penting untuk rehabilitasi seismik proaktif guna meningkatkan kemampuan layanan jaringan pasca gempa.

Sistem Air, Ketahanan, dan Sistem Listrik/Tenaga

Sub-bagian ini memberikan ringkasan penelitian lanjutan dalam berbagai aplikasi infrastruktur terkait sistem air, ketahanan, dan sistem listrik/tenaga. Sehubungan dengan hal tersebut, tinjauan pengetahuan dan penggunaan berbagai teknik AI terkini dan tercanggih disajikan. Dimulai dengan sistem air, proses jaringan analitik fuzzy dan analisis minimum cut-set digunakan untuk penilaian keandalan jaringan distribusi air dengan memperkenalkan kerangka kerja yang menilai keandalan mekanis dan hidraulik jaringan air. Aplikasi lain dari teknik AI untuk sistem air meliputi deteksi kebocoran dan geolokasi di mana pembelajaran terawasi dan klasifikasi (yaitu, jaringan saraf tiruan dan mesin vektor pendukung) digunakan untuk deteksi dini kebocoran berpotensi tinggi, geolokasinya, dan penilaian akurasi deteksi dalam sistem distribusi air.

Selain itu, penelitian dilakukan untuk memprediksi volume limpasan yang ditangkap dari daerah aliran sungai oleh perkerasan permeabel menggunakan jaringan saraf tiruan. Melanjutkan dengan sistem air, hutan acak digunakan dalam representasi topologi kolokasi geospasial untuk mengkarakterisasi konektivitas jaringan antarmuka distribusi air-transportasi dan mengidentifikasi atribut nodal yang paling prediktif dari profil konektivitas tertentu. Contoh lain untuk penggunaan teknik AI dalam sistem yang berhubungan dengan air termasuk bendungan. Sehubungan dengan itu, sambil mempertimbangkan aktivitas pemeliharaan pintu pelimpah, memperkirakan probabilitas luapan bendungan dimungkinkan menggunakan jaringan Bayesian. Selain itu, jaringan saraf tiruan dan K-tetangga terdekat digunakan untuk penilaian bahaya infrastruktur bendungan dengan mengevaluasi dan memprediksi tingkat potensi bahaya bendungan. Regresi proses Gaussian juga telah digunakan dalam pemantauan keamanan bendungan dengan menyajikan model perpindahan untuk pemantauan kesehatan bendungan gravitasi beton, yang dapat memodelkan efek suhu dengan menggunakan data suhu udara jangka panjang.

Di sisi lain, berbagai teknik dan algoritma AI digunakan untuk berbagai aplikasi terkait ketahanan dan sistem kelistrikan/tenaga. Dalam hal ini, pembelajaran mesin (DL), visi mesin (machine vision), dan CNN mendalam (deep CNN) digunakan untuk mengkaji cara meningkatkan ketahanan di sektor kelistrikan dengan mendeteksi ancaman terhadap infrastruktur kritis sebelum kegagalan terjadi. Selain itu, jaringan Bayesian digunakan untuk mengembangkan pendekatan pemodelan dan penilaian keandalan jaringan distribusi daya.

Selain itu, regresi linier, regresi vektor pendukung, dan jaringan saraf tiruan telah diterapkan untuk tujuan yang berkaitan dengan biaya proyek transmisi daya dengan menyajikan model estimasi biaya berbasis data yang memanfaatkan arsitektur data besar untuk mengelola data besar dan beragam yang diperlukan untuk proyek transmisi daya. Sedangkan untuk aplikasi terkait optimasi, algoritma genetika hibrida telah menunjukkan nilai yang besar dalam ketahanan pascabencana jaringan jalan raya-jembatan dengan digunakan untuk menentukan rute inspeksi optimal dan jadwal restorasi untuk jaringan jalan raya-jembatan yang rusak berdasarkan memaksimalkan waktu tempuh jaringan.

Selain itu, penelitian telah dilakukan untuk pemodelan zona evakuasi dengan mengembangkan metode berbasis data berbasis sel grid untuk memprediksi zona evakuasi di

masa depan di bawah perubahan iklim untuk membantu dalam evaluasi ketahanan sistem transportasi dalam menghadapi bencana alam. Terakhir, jaringan saraf tiruan—yaitu feedforward, Elman, dan nonlinier autoregresif eksogen (NARX)—diterapkan untuk menemukan dan memprediksi kinerja dan efisiensi kolektor pelat datar.

Aplikasi dalam Rekayasa dan Manajemen Konstruksi

AI telah digunakan dalam berbagai aplikasi rekayasa dan manajemen konstruksi. Aplikasi ini terutama meliputi: (1) aktivitas terkait konstruksi; (2) perencanaan; dan (3) manajemen fasilitas.

Aplikasi Aktivitas Terkait Konstruksi

Bagian ini bertujuan untuk memberikan ringkasan penelitian terkini dalam aplikasi yang terkait dengan aktivitas terkait konstruksi. Sehubungan dengan hal tersebut, tinjauan pengetahuan dan penggunaan berbagai teknik AI terkini dan terbaru disajikan. Pengenalan otomatis tindakan tenaga kerja dimungkinkan berkat kemampuan luar biasa dari teknik ML (yaitu k-nearest neighbor, multilayer perceptron, pohon keputusan, dan mesin vektor pendukung). K-nearest neighbor juga digunakan dengan penalaran berbasis kasus untuk perencanaan konstruksi pondasi dalam.

Studi tentang dampak dinamika tenaga kerja dan variabel tempat kerja terhadap produktivitas industri konstruksi dilakukan dengan mengandalkan analisis ekonometrika deret waktu berdasarkan model autoregresi vektor, Indikator Produktivitas. Selain itu, penambangan aturan asosiasi dan jaringan Bayesian digunakan untuk mengidentifikasi hubungan antara cacat dan probabilitas kemunculannya. Lebih lanjut, sebuah metode untuk mendeteksi komponen struktural beton dalam citra berwarna diusulkan berdasarkan pemrosesan citra, model campuran Gaussian, jaringan saraf tiruan, dan mesin vektor pendukung. Pohon keputusan dan klasifikasi Bayesian naif digunakan untuk memfasilitasi analisis dan prediksi risiko keterlambatan proyek yang akurat guna membantu mengatasi kelebihan jadwal yang sering terjadi dalam industri konstruksi. Selain itu, integrasi pengajuan lapangan dalam penjadwalan proyek telah dilakukan menggunakan hutan acak dengan menambang data proyek untuk memperkirakan penundaan selama proyek dan untuk memperkirakan kemungkinan penerimaan permintaan pengajuan.

Selain itu, pengelompokan (maksimalisasi ekspektasi) digunakan untuk mengusulkan pendekatan yang dapat mengumpulkan pengetahuan berharga dari data yang sebelumnya tidak dianalisis untuk secara signifikan meningkatkan praktik manajemen sumber daya dan tenaga kerja. Pembelajaran penguatan digunakan untuk memeriksa dampak pembelajaran dalam proses pengambilan keputusan penawaran untuk membantu mendapatkan hasil yang optimal dalam jangka panjang. Aplikasi lain dari teknik AI dalam aktivitas terkait konstruksi adalah estimasi jadwal hingga selesai melalui jaringan saraf memori jangka pendek (jaringan saraf umpan maju untuk masalah nonsekuensial dan jaringan saraf berulang untuk masalah sekuensial).

Arsitektur memori jangka pendek juga digunakan dengan pemrosesan bahasa alami untuk mengembangkan model peninjauan spesifikasi otomatis dan kerangka kerja ekstraksi informasi yang digunakan untuk peninjauan spesifikasi konstruksi. Pohon Chow–Liu dan

pengelompokan k-means digunakan untuk mengembangkan kerangka kerja yang mengukur tingkat ketidakpastian dan pembagian informasi dalam diskusi kendala dalam rapat perencanaan konstruksi. Selain itu, sebuah metode diusulkan untuk menawarkan pendekatan estimasi berjenjang untuk prakiraan biaya konstruksi yang akurat pada fase konseptual proyek konstruksi menggunakan regresi linier dan jaringan saraf tiruan.

Dengan cara lain, banyak teknik dan algoritma optimasi berbasis AI digunakan dalam berbagai aplikasi terkait aktivitas konstruksi. Sehubungan dengan itu, algoritma genetika, bersama dengan k-nearest neighbor, menunjukkan kemampuan untuk memperkirakan cadangan manajemen berdasarkan rasio kinerja biaya dan jadwal proyek konstruksi internasional. Selain itu, optimasi swarm partikel dan algoritma genetika, dikombinasikan dengan teori himpunan fuzzy, digunakan untuk optimasi waktu-biaya-sumber daya dalam perencanaan proyek konstruksi.

Lebih lanjut, penelitian dilakukan—berdasarkan algoritma genetika—untuk mengusulkan model berbasis simulasi guna menemukan rencana pengangkutan yang optimal untuk konstruksi gedung bertingkat tinggi dengan bentuk tidak beraturan dan meminimalkan total biaya sekaligus memenuhi batasan "waktu pengangkutan total" dan "waktu tempuh rata-rata". Algoritma genetika juga digunakan untuk mengevaluasi kebijakan penempatan material proaktif dan menyajikan kerangka kerja terintegrasi untuk menentukan tata letak optimal penempatan material yang menghasilkan waktu pengangkutan material minimum. Terakhir, pemrograman kendala telah menunjukkan penerapannya dalam mengoptimalkan jadwal, baik pada tahap perencanaan awal maupun sebelum konstruksi untuk proyek dengan persyaratan dan kendala yang terus berkembang.

Aplikasi Perencanaan

Bagian ini bertujuan untuk memberikan ringkasan penelitian terkini dalam berbagai aplikasi perencanaan. Perlu disebutkan bahwa bagian ini tidak berfokus pada perencanaan dalam aspek-aspek terkait manajemen konstruksi (yang telah disinggung di bagian sebelumnya), melainkan pada aplikasi perencanaan yang terkait dengan pertimbangan manajemen umum dalam domain teknik sipil. Sehubungan dengan hal tersebut, tinjauan pengetahuan dan penggunaan berbagai teknik AI terkini dan terbaru disajikan. Regresi vektor pendukung digunakan dalam perencanaan strategis mitigasi kekeringan dengan menyajikan kerangka kerja pendukung keputusan untuk menilai peran langkah-langkah strategis dan taktis dalam kesiapsiagaan dan mitigasi kekeringan.

Selain itu, perencanaan inspeksi platform jaket dipermudah melalui jaringan Bayesian dengan mengevaluasi kondisinya di bawah pengaruh kerusakan, deteriorasi, dan beban yang diterapkan, serta dengan menghitung probabilitas kegagalan elemen struktural. Proses keputusan Markov yang dapat diamati sebagian dan adaptif Bayes (BA-POMDP) digunakan untuk membantu perencanaan dan pembelajaran optimal bagi pengelolaan ladang angin dengan mengembangkan pendekatan yang dapat belajar di lingkungan yang tidak pasti untuk mengurangi total biaya pengelolaan ladang angin.

Selain itu, perencanaan operasi waduk air multioutlet dimungkinkan dengan menggunakan pembelajaran penguatan mode batch (yaitu, iterasi Q yang disesuaikan) untuk

memperhitungkan target kuantitas dan kualitas demi pengelolaan sistem sumber daya air yang lebih baik.

Di sisi lain, banyak teknik dan algoritma optimasi berbasis AI digunakan dalam berbagai aplikasi perencanaan. Terkait dengan itu, algoritma evolusioner (yaitu, algoritma genetika, optimasi gerombolan partikel, dan algoritma lompatan katak acak) digunakan untuk mengembangkan aturan optimal untuk area irigasi multitanaman yang terkait dengan kebijakan operasi waduk dalam sistem irigasi waduk. Selain itu, optimasi berbasis skenario telah menunjukkan efektivitasnya dalam perencanaan multiperioda dan desain infrastruktur pasokan air. Terakhir, algoritma genetika digunakan:

1. untuk merencanakan layanan tanggap darurat dalam keselamatan jalan raya dan kecelakaan lalu lintas;
2. metode untuk perencanaan diferensiasi antibencana dari sistem distribusi daya, yang juga mengandalkan metode pohon rentang minimum;
3. merencanakan perluasan kapasitas sistem penyediaan air tanah dengan kendala penurunan tanah dengan juga mengandalkan pemrograman dinamis diferensial terkendala;
4. merencanakan pengembangan air tanah pertanian yang optimal untuk irigasi dan memastikan pola tanam zonal yang optimal dengan memperhatikan kendala kedalaman muka air tanah maksimum dan aliran antar akuifer pada kesetimbangan dinamis; dan
5. merencanakan kebijakan investasi yang optimal untuk aset infrastruktur dengan mengevaluasi keseimbangan antara total pengeluaran dan pencegahan kegagalan aset di masa mendatang (kemudahan servis).

Aplikasi Manajemen Fasilitas

Subbagian ini memberikan ringkasan penelitian kontemporer dalam berbagai aplikasi manajemen fasilitas. Terkait dengan hal tersebut, tinjauan pengetahuan dan penggunaan berbagai teknik AI terkini dan terbaru disajikan. Pemrosesan bahasa alami dan penambahan teks (yaitu, Bayes naif, regresi logistik, dan mesin vektor pendukung) digunakan untuk prediksi rencana kerja untuk manajemen fasilitas melalui peramalan otomatis jenis reaksi (reguler atau mendesak) dan kru yang diperlukan berdasarkan deskripsi tekstual dari permintaan layanan. Banyak tantangan telah hadir selama beberapa dekade dalam industri konstruksi, salah satunya terkait dengan pemeliharaan tertunda dalam manajemen fasilitas.

Sehubungan dengan itu, strategi mitigasi untuk pemeliharaan tertunda dirancang berdasarkan analisis pohon kesalahan dan analisis jaringan Bayesian untuk menyediakan strategi prioritas paket total untuk evaluasi dan diagnosis persyaratan pemeliharaan tertunda bangunan. Selain itu, menggunakan DL untuk mengembangkan sistem manajemen fasilitas yang memperkirakan posisi dan orientasi pengguna di dalam ruangan dengan membandingkan perspektif pengguna dengan pemodelan informasi bangunan (BIM) yang sedang mengalami perkembangan dan penggunaan substansial dalam industri konstruksi.

Penelitian dilakukan untuk memprediksi masa pakai cat eksterior pada fasad yang telah dirender dan mengidentifikasi faktor-faktor yang berpengaruh signifikan terhadap laju

degradasi cat menggunakan model regresi linier biasa. Lebih lanjut, pengambilan keputusan multi-kriteria fuzzy digunakan untuk sistem penilaian risiko dan pemeliharaan fasilitas guna membantu manajer layanan dalam memilih kebijakan pemeliharaan untuk satu peralatan dan dalam menentukan prioritas pemeliharaan komponen peralatan pada tahap awal operasi dan pemeliharaan.

Di sisi lain, banyak teknik dan algoritma optimasi berbasis AI digunakan dalam berbagai aplikasi manajemen fasilitas. Sehubungan dengan hal tersebut, algoritma Dijkstra yang dimodifikasi dan algoritma pencarian A* menunjukkan kemampuan luar biasa dalam penjadwalan perintah kerja pemeliharaan fasilitas. Terakhir, algoritma genetika digunakan untuk: (1) merencanakan pemeliharaan fasilitas rumah sakit dengan mengembangkan pendekatan pemeliharaan optimal yang berpusat pada keandalan yang memperhitungkan tugas-tugas pemeliharaan dan perkiraan waktu henti yang disebabkan oleh kegagalan sistem rumah sakit (yaitu, gas medis, pemanas, ventilasi, dan pendingin udara (HVAC) primer, HVAC sekunder, dan lift); (2) mengkaji pemeliharaan, perbaikan, dan renovasi (MR&R) gedung dan dengan mengidentifikasi serta memilih aktivitas MR&R gedung multi-tahun sehingga kinerja fasilitas dapat dimaksimalkan dan biaya siklus hidup diminimalkan; dan (3) meminimalkan profil biaya pemeliharaan, perbaikan, dan rehabilitasi gedung dengan menyesuaikan waktu beberapa aktivitas ke titik yang lebih awal dari jadwal awal pemeliharaan, perbaikan, dan rehabilitasi.

Aplikasi dalam Keselamatan

AI telah digunakan dalam berbagai aplikasi keselamatan. Aplikasi ini terutama mencakup (1) manajemen keselamatan konstruksi; (2) analisis kecelakaan; dan (3) keselamatan kebakaran.

Manajemen Keselamatan Konstruksi

Subbagian ini merangkum penelitian terkini dalam berbagai aplikasi manajemen keselamatan konstruksi. Sehubungan dengan hal tersebut, tinjauan pengetahuan dan penggunaan berbagai teknik AI terkini dan terbaru disajikan. Mesin vektor pendukung digunakan untuk keselamatan perancah guna memungkinkan pemantauan perancah besar dan kompleks secara real-time di lokasi konstruksi guna mencegah pekerja konstruksi dari keruntuhan perancah yang tragis. Mesin vektor pendukung juga digunakan dengan reduksi dimensi untuk pemodelan dan klasifikasi tindakan tidak aman dalam konstruksi. Selain itu, estimasi hubungan yang tidak diketahui antara nilai/data pemantauan dan risiko keselamatan lubang pondasi dalam dimungkinkan dengan penerapan hutan acak.

Upaya penelitian juga mengusulkan sebuah model yang memanfaatkan langkah-langkah terkait keselamatan yang ada dalam suatu organisasi untuk mengevaluasi kinerja keselamatan secara andal dengan mengandalkan penalaran berbasis kasus. Pemrosesan bahasa alami diterapkan untuk mengembangkan pendekatan berbasis aturan untuk mengekstraksi elemen pengetahuan domain dari dokumen teks dalam domain manajemen keselamatan konstruksi. Algoritma genetika telah digunakan untuk mengoptimalkan penempatan kamera untuk cakupan lokasi dengan mempertimbangkan dinamika oklusi yang disebabkan oleh dinding samping dan penyangga selama penggalian di proyek stasiun metro.

Selain itu, penelitian dilakukan untuk menggabungkan dan mengintegrasikan data dari beberapa sumber dengan komponen analisis dan simulasi secara efisien dari segi biaya, tenaga kerja, dan waktu berdasarkan jaringan saraf tiruan.

Selain itu, algoritma transformasi kelas ekivalensi (EclaT) dan aturan asosiasi digunakan untuk mengembangkan metode prediksi guna meningkatkan identifikasi bahaya di tempat kerja. Analisis kelas laten dan analisis korespondensi ganda dilakukan untuk memeriksa laporan kecelakaan fatalitas konstruksi demi manajemen risiko yang efektif dan pengendalian yang lebih baik atas keseluruhan sistem sosioteknis. Banyak teknik dan algoritma pemrosesan citra berbasis AI digunakan dalam berbagai aplikasi manajemen keselamatan konstruksi. Sehubungan dengan itu, visi komputer dan inferensi fuzzy digunakan untuk menyajikan sistem penilaian keselamatan di lokasi kerja guna memantau kecelakaan yang ditabrak oleh entitas yang bergerak. Prediksi lintasan gerak pekerja dan peralatan yang akan datang di lokasi konstruksi dimungkinkan dengan mengandalkan visi komputer, jaringan memori jangka pendek panjang, dan jaringan kepadatan campuran.

Visi mesin dan jaringan saraf fuzzy telah menunjukkan kemampuannya dalam mengembangkan sistem evaluasi kecerdasan waktu nyata (real-time) untuk mencegah tabrakan antara pekerja dan mesin dalam konstruksi lokasi penggalian. Parameterisasi citra telah memberikan nilai tambah yang besar dalam pengembangan metode identifikasi waktu nyata berbasis kerangka dengan menggabungkan teknologi berbasis citra, pengetahuan keselamatan konstruksi, dan teori ergonomi untuk mengenali perilaku tidak aman. Sistem peringatan waktu nyata dikembangkan menggunakan data visual yang diperoleh dari kamera yang tersedia di alat berat untuk melindungi pekerja dari situasi yang berpotensi membahayakan yang melibatkan pengoperasian alat berat melalui ketergantungan pada DL (visi komputer dan R-CNN yang lebih cepat).

Analisis Kecelakaan

Subbagian ini memberikan ringkasan penelitian terkini dalam berbagai aplikasi analisis kecelakaan. Terkait hal tersebut, tinjauan pengetahuan dan penggunaan berbagai teknik AI terkini dan terancang disajikan. Mesin vektor pendukung digunakan untuk menentukan risiko keselamatan yang dapat muncul selama konstruksi pondasi lubang dalam. Selain itu, eksplorasi faktor kognitif yang memengaruhi perilaku tidak aman saat bekerja di ketinggian dilakukan menggunakan beberapa teknik ML, yaitu regresi linier berganda, jaringan saraf tiruan, dan pohon keputusan. Selain itu, tindakan tidak aman pengemudi di persimpangan yang dikontrol sinyal dipelajari dengan mengekstraksi informasi dari narasi laporan kecelakaan untuk lebih memahami skenario kecelakaan menggunakan pemrosesan bahasa alami, pohon klasifikasi yang ditingkatkan, dan mesin vektor pendukung.

Demikian pula, pohon klasifikasi dan pemrosesan bahasa alami (misalnya, penambahan teks) digunakan untuk menafsirkan mekanisme kecelakaan listrik/sengat listrik sebagai rangkaian kesalahan keputusan di seluruh proses tugas. Pemrosesan bahasa alami juga digunakan untuk mengusulkan sistem manajemen pengetahuan untuk kasus kecelakaan konstruksi guna mengidentifikasi kondisi berbahaya dan mencegah kecelakaan dengan mengendalikan risiko di lokasi. Lebih lanjut, penelitian dilakukan untuk mempelajari

kecelakaan perlintasan sebidang jalan raya-rel dan risiko tabrakan menggunakan jaringan saraf tiruan.

Namun, banyak teknik dan algoritma pengelompokan berbasis AI digunakan dalam berbagai aplikasi analisis kecelakaan. Sehubungan dengan itu, pengelompokan spektral, dan teknik penambangan data (misalnya, algoritma Apriori dan aturan asosiasi) digunakan untuk menentukan kombinasi kritis penyebab kematian keselamatan di lokasi konstruksi. Penelitian dilakukan untuk mengusulkan model yang memprediksi hasil insiden konstruksi untuk menentukan tindakan pencegahan yang diperlukan menggunakan jaringan saraf tiruan dan analisis pengelompokan kelas laten (LCCA).

Demikian pula, analisis kelas laten diterapkan untuk mengklasifikasikan akar penyebab kecelakaan fatal jatuh dari ketinggian dan menganalisis karakteristiknya. Analisis komponen utama (PCA) dan analisis kluster digunakan untuk melakukan analisis kecelakaan fatal dalam hal waktu terjadinya dan bagaimana kecelakaan tersebut terjadi dalam perdagangan konstruksi. Demikian pula, analisis faktor telah memberikan kemampuan dalam mengidentifikasi penyebab pengerjaan ulang yang mengarah pada peningkatan risiko keselamatan dan dalam menentukan dimensi kausal utama yang mendasari pengerjaan ulang dan insiden keselamatan. Faktanya, industri konstruksi adalah bisnis yang rumit yang menggabungkan berbagai ketidakpastian, risiko, dan kondisi yang selalu berubah.

Selain itu, investigasi kesalahan pengoperasian mesin pelindung dan kecelakaan berdasarkan Teknik Analisis Retrospektif dan Prediktif Kesalahan Kognitif dilakukan dengan menggunakan penambangan data dan analisis kluster (algoritma k-means dan aturan asosiasi). Aturan asosiasi juga digunakan untuk mempelajari karakteristik kecelakaan lalu lintas jalan tol dan untuk menganalisis faktor-faktor yang memengaruhi dan penyebab cedera dan kematian yang menyebabkan kecelakaan lalu lintas tersebut. Akhirnya, metode pengelompokan blok diterapkan untuk menyelidiki heterogenitas dalam kumpulan data kecelakaan truk besar dan memberikan wawasan tambahan untuk mengembangkan potensi tindakan pencegahan dan strategi.

Keselamatan Kebakaran

Subbagian ini memberikan ringkasan penelitian terkini dalam berbagai aplikasi keselamatan kebakaran. Sehubungan dengan itu, tinjauan pengetahuan terkini dan terkini serta penggunaan berbagai teknik AI disajikan. Beberapa teknik ML (yaitu Naive Bayes, model linear tergeneralisasi, regresi logistik, margin besar cepat, DL, pohon keputusan, hutan acak, pohon penguat gradien, dan mesin vektor pendukung) digunakan untuk memeriksa fitur-fitur utama yang mengatur kecenderungan spalling akibat kebakaran pada kolom beton bertulang dan untuk mengembangkan alat untuk prediksi spalling seketika. Selain itu, manajemen keselamatan kebakaran di lokasi konstruksi bangunan ditingkatkan dengan membangun model pengenalan api dan mengembangkan deteksi kebakaran konstruksi waktu nyata menggunakan CNN.

Lebih lanjut, analisis regresi menunjukkan nilainya dalam mengeksplorasi pengaruh visibilitas kebakaran, suara alarm kebakaran, dan karakteristik individu terhadap waktu pra-pergerakan evakuasi kebakaran individu di gedung komersial bawah tanah. Lebih lanjut,

perilaku manusia dalam pra-evakuasi kebakaran dipelajari untuk menyelidiki faktor-faktor yang memengaruhi pengambilan keputusan penghuni gedung selama peristiwa kebakaran menggunakan hutan acak. Demikian pula, perilaku pra-evakuasi orang-orang di bawah kebakaran diperiksa menggunakan mesin vektor pendukung.

Di sisi lain, banyak teknik dan algoritma optimasi berbasis AI telah digunakan dalam berbagai aplikasi keselamatan kebakaran. Sehubungan dengan itu, pemrograman genetik, bersama dengan visi komputer, digunakan untuk memperkenalkan alat evaluasi berbasis kebakaran guna memahami perilaku struktural dalam kondisi kebakaran. Selain itu, optimasi kumpulan partikel dan evolusi diferensial mencerminkan kemampuannya dalam menyediakan skema terintegrasi untuk memecahkan masalah alokasi anggaran yang ketat dalam melindungi bangunan bersejarah dari kebakaran. Terakhir, jaringan saraf tiruan yang dioptimalkan oleh algoritma genetik dirancang untuk memprediksi kapasitas lentur sisa balok beton bertulang setelah kebakaran.

Ketergantungan pada teknik AI telah meningkat secara substansial dalam beberapa tahun terakhir, terutama dengan kemajuan teknologi dan kemampuan komputasi. Bab ini menyajikan penelitian mutakhir di bidang AI dengan pertimbangan khusus pada tiga domain aplikasi berikut: sistem infrastruktur sipil, rekayasa dan manajemen konstruksi, serta keselamatan. Sehubungan dengan hal tersebut, para akademisi dan upaya penelitian telah memainkan peran yang luar biasa dalam memanfaatkan teknik AI di berbagai domain, terutama melalui usulan teknik dan algoritma yang lebih canggih dan mutakhir.

Tren dan aplikasi teknik AI saat ini dan yang sedang berkembang, serta bagaimana berbagai alat dan algoritma digunakan untuk membantu dalam berbagai pengambilan keputusan dan untuk mengatasi berbagai masalah serta tantangan yang muncul, telah disajikan. Bab ini telah menawarkan pengetahuan yang komprehensif dan terkini tentang penggunaan teknik AI saat ini dan akan sangat berharga bagi mahasiswa, peneliti, dan praktisi karena telah mengkonsolidasikan informasi dan literatur yang ada dan terbaru, serta mengkategorikannya ke dalam berbagai bidang aplikasi, yang menawarkan pemahaman yang lebih jelas tentang berbagai teknik AI dalam berbagai domain.

7.4 KESIMPULAN

Ketergantungan pada teknik kecerdasan buatan (*Artificial Intelligence/AI*) telah meningkat secara signifikan dalam beberapa tahun terakhir, terutama seiring dengan kemajuan teknologi dan kemampuan komputasi. Bab ini menyajikan penelitian mutakhir mengenai AI dengan fokus khusus pada tiga bidang aplikasi utama, yaitu sistem infrastruktur sipil, rekayasa dan manajemen konstruksi, serta aspek keselamatan. Dalam kaitannya dengan hal tersebut, para akademisi dan peneliti memiliki peran yang sangat penting dalam memanfaatkan teknik-teknik AI di berbagai bidang tersebut, khususnya melalui pengembangan metode dan algoritma yang lebih canggih serta inovatif.

Tren terkini dan yang sedang berkembang juga telah dipaparkan, termasuk berbagai aplikasi AI, serta bagaimana beragam alat dan algoritma digunakan untuk membantu pengambilan keputusan, mengatasi berbagai masalah, dan menjawab tantangan baru yang

muncul di lapangan. Bab ini memberikan wawasan yang komprehensif sekaligus terkini mengenai pemanfaatan teknik-teknik AI, sehingga dapat menjadi sumber berharga bagi mahasiswa, peneliti, maupun praktisi. Hal ini dikarenakan bab ini telah berhasil mengonsolidasikan informasi yang sudah ada dengan temuan-temuan terbaru, menyusun literatur dalam berbagai bidang aplikasi, dan mengategorikan penggunaannya sehingga pembaca dapat memperoleh pemahaman yang lebih jelas mengenai beragam teknik AI dalam konteks domain yang berbeda.

BAB 8

KECERDASAN BUATAN DALAM MATERIAL BETON SCIENTOMETRIK

8.1 PENDAHULUAN

Populasi dunia telah tumbuh dari 1,5 miliar menjadi 7,7 miliar selama seratus tahun terakhir, dengan lebih dari separuh umat manusia saat ini tinggal di wilayah perkotaan. Seiring dengan pertumbuhan populasi dunia, urbanisasi global akan berkembang pesat. Diperkirakan pada tahun 2050, dua dari tiga orang akan tinggal di perkotaan. Laju pembangunan perkotaan yang begitu tinggi membutuhkan material dalam jumlah besar untuk pembangunan perumahan, bangunan komersial, fasilitas sanitasi, dan infrastruktur lainnya.

Beton merupakan material bangunan utama untuk industri konstruksi dan infrastruktur. Meskipun telah dilakukan penelitian dan analisis selama puluhan tahun, beberapa pertanyaan ilmiah dan rekayasa tentang material beton, termasuk optimasi desain campuran dan prediksi masa pakai, masih belum terjawab. Meskipun sebagian besar penelitian beton awal mengandalkan pengetahuan dan intuisi ahli, eksperimen coba-coba, atau pemodelan fisik, kemajuan terbaru dalam teknik berbasis data seperti kecerdasan buatan (AI) dapat memberikan perspektif baru untuk menjawab pertanyaan penelitian yang ada.

Selama beberapa tahun terakhir, AI telah menarik perhatian dunia sebagai "paradigma keempat sains" karena pertumbuhan eksponensial dalam daya komputasi, aksesibilitas repositori data yang lebih tinggi, dan ketersediaan perangkat ilmu data yang lebih luas. Dibandingkan dengan eksperimen yang padat karya atau simulasi komputasi yang mahal, teknik AI memanfaatkan data yang ada, mempelajari pola secara otomatis, dan melakukan tugas tanpa instruksi eksplisit.

Teknik berbasis data tersebut telah menawarkan alternatif untuk mempercepat desain dan optimasi campuran beton dengan cara yang lebih efektif: kumpulan data campuran beton yang besar dibangun dan dimasukkan ke dalam model AI; model kemudian menyaring dan menghasilkan campuran baru dengan sifat yang diinginkan; dan campuran terbaik dapat diidentifikasi dan divalidasi melalui uji eksperimental dan komputasi, dengan hasilnya ditambahkan ke kumpulan data yang terkumpul dan dikalibrasi secara iteratif. Namun demikian, interaksi antara AI dan beton masih dalam tahap awal dan kekuatan penuh AI dalam penelitian beton masih jauh dari terwujud. Oleh karena itu, ikhtisar kemajuan penelitian saat ini dan peluang di masa depan akan bermanfaat bagi adopsi AI yang lebih luas dalam industri konstruksi.

Studi tinjauan AI yang ada di bidang beton telah memberikan kontribusi yang berharga. Namun, studi-studi ini memiliki beberapa keterbatasan. Pertama, studi-studi ini seringkali mengadopsi perspektif yang relatif sempit, berfokus pada aplikasi AI yang terbatas dalam ilmu beton. Misalnya, Nunez dkk. (2021) mengkaji berbagai model AI untuk prediksi akurat kuat tekan beton; Ben Chaabene dkk. (2020) memperluas cakupannya ke aplikasi AI dalam prediksi

sifat mekanik beton, sementara DeRousseau dkk. (2018) membahas beberapa metode komputasi yang digunakan untuk mengoptimalkan desain campuran beton.

Kedua, studi tinjauan sebelumnya sebagian besar bergantung pada tinjauan dan penilaian manual, yang dapat menyebabkan interpretasi subjektif. Dengan demikian, studi tinjauan ini tidak menawarkan gambaran lengkap tentang struktur pengetahuan penelitian AI saat ini dalam domain konkret. Sebagai upaya pertama untuk mengisi kesenjangan ini, bab ini dimaksudkan untuk menyajikan evaluasi kuantitatif dari pola pengetahuan dan menangkap minat penelitian dan tren AI yang muncul dalam sains konkret. Untuk tujuan ini, bab ini menggunakan teknik scientometrik untuk melakukan analisis kuantitatif pada literatur mengenai AI dalam material konkret. Scientometrik adalah cabang informatika yang mengkuantifikasi fitur dan karakteristik sains dan penelitian ilmiah, dan mengungkap tren penelitian dan struktur pengetahuan yang muncul dalam domain penelitian.

Sementara tinjauan manual memberikan ikhtisar yang mendalam tentang bidang penelitian, perangkat scientometrik mengambil literatur ilmiah sebagai masukan dan menghasilkan visualisasi dan pemetaan interaktif dengan cara yang lebih efektif dan efisien. Tujuan dari bab ini adalah untuk: (1) menganalisis secara kuantitatif literatur yang ada dalam topik tersebut dengan teknik scientometrik (yaitu, analisis ko-kemunculan kata kunci dan analisis ko-sitasi dokumentasi); (2) menyoroti topik penelitian terkini dan aplikasi AI pada material beton; dan (3) mengidentifikasi kesenjangan penelitian untuk adopsi AI lebih lanjut pada industri konstruksi.

8.2 SURVEI LITERATUR

Bab ini menganalisis data yang diambil dari basis data *Web of Science* (WoS) Core Collection, salah satu sumber data bibliografi paling mapan dan mencakup jurnal ilmiah berkualitas tinggi yang telah melalui tinjauan sejawat dan diterbitkan di seluruh dunia. Kombinasi dengan basis data bibliografi lain (seperti Google Scholar dan Scopus) tidak dipertimbangkan karena kesulitan dalam memeriksa duplikat publikasi dan menangani berbagai format data dari berbagai basis data.

Kata kunci dipilih berdasarkan studi tinjauan terkait dan pencarian iteratif di platform WoS. Hasilnya, daftar kata kunci untuk topik yang terkait dengan sains konkret dan AI dibuat, dengan string kueri: ("concrete" ATAU "cement" ATAU "cementitious") DAN ("artificial intelligence" ATAU "machine learning" ATAU "deep learning" ATAU "neural network*" ATAU "support vector machine*" ATAU "random forest" ATAU "decision tree*" ATAU "k-nearest" ATAU "k nearby" ATAU "k nearby" ATAU "k-nn" ATAU "knn" ATAU "k-mean*" ATAU "k mean*" ATAU "gaussian process*"). Perhatikan bahwa karakter wildcard * digunakan untuk menangkap bentuk jamak, misalnya, "neural network*" cocok dengan "neural network" dan "neural networks".


Pencarian kata kunci dilakukan pada istilah topik dari judul, abstrak, kata kunci penulis, dan kata kunci plus (dihasilkan secara otomatis dari judul artikel yang dikutip oleh WoS) dalam sebuah rekaman. Periode pencarian ditetapkan untuk mencakup 30 tahun terakhir, dari

Januari 1990 hingga Desember 2020, yang cukup berdasarkan pencarian awal kami untuk mewakili perkembangan AI dalam domain konkret.

Bahasa publikasi dibatasi pada bahasa Inggris, dan "jenis dokumen" ditetapkan ke "artikel" sehingga evolusi bidang tersebut dapat diwakili oleh penelitian berkualitas tinggi dan asli. Kami selanjutnya membatasi "area penelitian" dengan operasi Boolean ("Teknologi Konstruksi & Bangunan" DAN "Ilmu Material" BUKAN "Ilmu Komputer"), karena kata kunci seperti "konkret" sering digunakan dalam arti lain dari kata-kata tersebut dalam bidang subjek lain, seperti ilmu komputer.

Hingga Oktober 2021, 440 dokumen telah diidentifikasi. Proses penyempurnaan manual lebih lanjut dilakukan untuk mengevaluasi artikel yang dikumpulkan dengan membaca judul sumber dan abstrak untuk inklusi/eksklusi. Pengecualian terutama untuk publikasi yang: (1) artikel tinjauan dan bab buku; (2) tidak terkait dengan ilmu beton (misalnya, berfokus pada material konstruksi lain seperti baja tetapi mengutip artikel terkait beton sebagai referensi); dan (3) tidak terkait dengan AI (misalnya, menerapkan model statistik tradisional seperti model regresi linier dan hanya memasukkan AI sebagai rekomendasi untuk penelitian mendatang). Pendekatan ini menyaring jumlah publikasi dari 440 menjadi 389.

Gambar 8.1 menyajikan daftar jurnal teratas tempat publikasi tentang AI untuk material beton telah diterbitkan. Ke-12 jurnal pada Gambar 8.1 memiliki faktor dampak lebih besar dari 1,7 pada tahun 2020, yang memberikan kredibilitas pada representasi basis data yang dikumpulkan. Mayoritas (lebih dari 50%) publikasi tentang AI dalam beton telah diterbitkan di Construction and Building Materials, yang ditemukan sebagai jurnal paling berpengaruh dalam domain penelitian ini menurut jumlah sitasi (6.993). Menariknya, meskipun jumlah publikasi dari Cement and Concrete Research berada di peringkat keempat, catatan sitasi jurnal ini berada di peringkat kedua di bidangnya. Steel and Composite Structures dan ACI Structural Journal menjadi sumber referensi utama untuk sitasi, meskipun keduanya tidak masuk dalam daftar 10 jurnal teratas dalam hal jumlah publikasi.




Gambar 8.1 10 jurnal teratas dalam hal jumlah publikasi dan sitasi di bidang AI dalam ilmu beton.

Catatan: Judul jurnal disajikan menggunakan singkatan berdasarkan standar ISO (Organisasi Standar Internasional).

Bidang penelitian AI dimulai sejak pertengahan abad ke-20 dan telah diperluas ke industri konstruksi pada tahun 1970-an; namun, adopsi AI dalam material beton baru dimulai pada awal tahun 1990-an. Studi pertama tentang AI dalam domain beton tampaknya adalah karya Pratt dan Sansalone (1992), yang diterbitkan dalam ACI Materials Journal pada tahun 1992, di mana AI digunakan untuk mengotomatiskan interpretasi sinyal untuk pengujian gema impak di lapangan. Hal ini diikuti oleh studi Mo dan Lin (1994), di mana mereka menggunakan AI untuk memodelkan perilaku dinding geser rangka beton bertulang.

Gambar 8.2 menunjukkan tren publikasi penelitian tentang AI dalam sains konkret dari tahun 1990 hingga 2020. Hal ini menunjukkan peningkatan minat penelitian yang relatif stabil dan bertahap pada akhir abad ke-20. Jumlah publikasi tidak mencapai dua digit hingga tahun 2009. Sejak saat itu, pertumbuhan eksponensial telah terlihat karena daya komputasi yang terus meningkat dan ketersediaan data eksperimen dan perangkat komputasi.

Model eksponensial digunakan untuk menyesuaikan data pada Gambar 8.2: $N(t) = N_0(1 + p)^{t-t_0}$, di mana $N(t)$ dan N_0 masing-masing adalah jumlah publikasi pada tahun t dan tahun awal $t_0 = 1990$. Parameter p mewakili tingkat persentase peningkatan tahunan. N_0 dan p ditentukan masing-masing sebesar 0,006 dan 0,376. Hal ini menunjukkan bahwa perkiraan peningkatan jumlah publikasi selama periode satu tahun adalah 37,6%, dan jumlah publikasi relevan pada tahun 2021 dan 2022 masing-masing dapat mencapai lebih dari 110 dan 160.



Gambar 8.2: Jumlah publikasi untuk aplikasi AI dalam ilmu konkret selama tahun 1990–2020.

8.3 ANALISIS KO-OKURENSI KATA KUNCI SEBAGAI MINAT PENELITIAN UTAMA

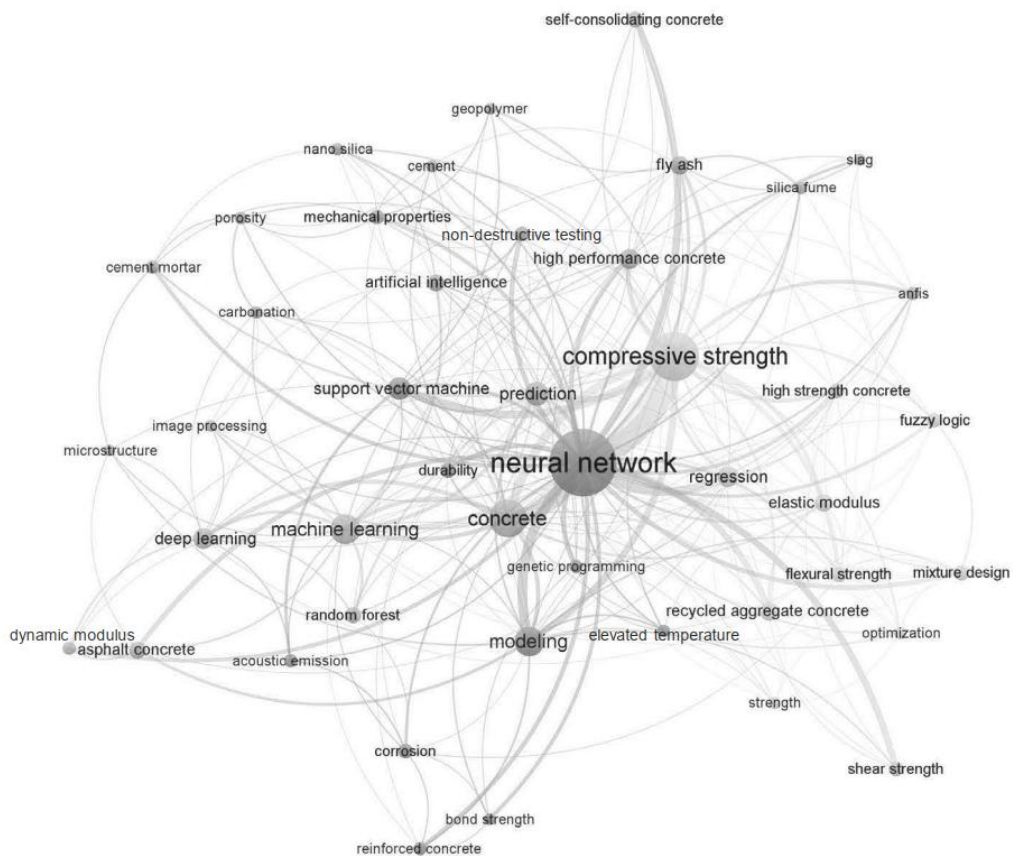
Kata kunci adalah kata atau frasa yang menyampaikan konten paling esensial dari sebuah dokumen yang dipublikasikan. Analisis kata kunci dapat menawarkan peluang untuk

mengungkap minat penelitian utama di bidang ilmiah apa pun. Untuk membangun dan memetakan domain pengetahuan antara AI dan material konkret, jaringan ko-okurensi kata kunci dikembangkan menggunakan VOS viewer. Ko-okurensi dua kata kunci dapat didefinisikan sebagai situasi ketika kedua kata kunci muncul bersamaan dalam sebuah publikasi.

Jaringan ko-okurensi kata kunci yang umum terdiri dari simpul (yaitu, kata kunci) dan tautan (yang menunjukkan hubungan antara pasangan simpul). Kekuatan hubungan antara dua kata kunci menunjukkan keterkaitan domain pengetahuan masing-masing. Visualisasi jaringan ko-okurensi kata kunci memberikan pemahaman tentang topik-topik penelitian yang ada dan bagaimana topik-topik tersebut dikembangkan dan dihubungkan secara intelektual.

Kata kunci dapat diekstraksi dari judul dan abstrak publikasi dengan pendekatan penambangan teks atau dari daftar kata kunci yang diberikan oleh penulis. Dalam penelitian ini, hanya kata kunci penulis yang digunakan untuk melakukan analisis dan memperoleh hasil yang dapat direproduksi dan dibaca. Istilah-istilah yang identik (seperti "jaringan saraf" dan "jaringan saraf"; "desain campuran" dan "desain campuran") digabungkan untuk akurasi analisis.

Namun, kata kunci seperti "beton", "beton kinerja tinggi", "beton agregat daur ulang", "beton aspal", "beton self-konsolidasi", "beton kekuatan tinggi", dan "beton bertulang" tetap ada dalam basis data, karena keberadaan mereka dan ketiadaan istilah mengenai jenis beton lain menunjukkan topik hangat dan minat penelitian untuk jenis beton tertentu.



Gambar 8.3: Jaringan kata kunci yang muncul bersamaan terkait penelitian AI pada material beton (tampilan kluster).

Contoh lain termasuk kata kunci "kekuatan", "kekuatan tekan", "kekuatan lentur", dan "kekuatan ikatan", yang merupakan kinerja mekanis beton yang dikeraskan. Jumlah minimum kemunculan kata kunci ditetapkan menjadi lima sehingga 45 dari 969 kata kunci dimasukkan dalam jaringan ko-kemunculan. Kriteria ini dipilih setelah studi terkait sebelumnya dan berdasarkan beberapa eksperimen untuk menghasilkan kluster optimal dalam jaringan. Metodologi penghitungan fraksional diadopsi untuk memfraksinasi bobot suatu tautan dengan mempertimbangkan jumlah kata kunci dalam suatu publikasi. Metode ini terbukti lebih baik daripada pendekatan penghitungan penuh tradisional.

Gambar 8.3 menyajikan jaringan kata kunci yang muncul bersamaan dengan 45 simpul dan 536 tautan. Dalam jaringan tersebut, setiap simpul merepresentasikan satu istilah kata kunci. Ukuran simpul dan label menunjukkan jumlah publikasi yang memiliki istilah terkait dalam daftar kata kunci. Jarak antara dua simpul menunjukkan keterkaitan antar simpul. Secara umum, semakin kecil jaraknya, semakin erat hubungan antar kata kunci. Lebar tautan merepresentasikan kekuatan tautan, yaitu jumlah publikasi di mana dua kata kunci muncul bersamaan.

Simpul dengan warna yang sama menunjukkan domain pengetahuan yang serupa di antara publikasi yang diteliti. Tabel 8.1 merangkum kemunculan kata kunci dan data jaringan terkait. Sebagaimana ditunjukkan pada Gambar 8.3 dan Tabel 8.1, beberapa minat penelitian telah mendapatkan perhatian khusus. Misalnya, kata kunci seperti "pemodelan", "prediksi", "regresi", dan "optimasi" telah sering digunakan dalam publikasi. Hal ini dapat dijelaskan oleh fakta bahwa tujuan utama pemanfaatan AI dalam beton adalah untuk memodelkan perilaku beton, memprediksi sifat beton, dan mengoptimalkan desain campuran beton untuk kinerja yang diinginkan.

Menariknya, "jaringan saraf tiruan" muncul paling sering di antara semua kata kunci, menunjukkan bahwa model tersebut merupakan yang paling umum digunakan, diikuti oleh mesin vektor pendukung dan hutan acak seperti ditunjukkan pada Tabel 8.1. Sebagai kata kunci kedua yang paling sering digunakan, "kuat tekan" mewakili hubungan terkuat dengan "jaringan saraf tiruan" (lihat Gambar 8.3). Hal ini menunjukkan bahwa aplikasi AI yang paling umum dalam ilmu beton adalah penerapan model jaringan saraf tiruan untuk prediksi kuat tekan beton, sesuai dengan penelitian lain. Kuat tekan dianggap sebagai salah satu parameter desain terpenting dalam aplikasi konstruksi, karena menentukan kapasitas beban struktur beton dan berkorelasi dengan beberapa sifat mekanik dan durabilitas beton, termasuk kuat tarik dan lentur, modulus elastisitas, dan impermeabilitas.

Prediksi kuat tekan beton sebagai fungsi proporsi campuran telah menjadi fokus penelitian untuk memfasilitasi optimasi desain campuran selama fase desain dan membantu penjadwalan proyek serta pengendalian mutu selama fase produksi. Meskipun teknik AI menjanjikan, Tabel 8.1 menunjukkan bahwa model lain seperti logika fuzzy, sistem inferensi neuro-fuzzy adaptif (ANFIS), dan pemrograman genetika kurang mendapat perhatian dalam penelitian beton.

Dengan demikian, penelitian di masa mendatang di bidang ini sebaiknya mengeksplorasi berbagai model AI (yaitu, model selain jaringan saraf tiruan) dan pengembangan serta pemanfaatan penuh berbagai model dapat menjadi bantuan yang menjanjikan dalam mempercepat adopsi AI dalam industri konstruksi.

Tabel 8.1: Daftar kata kunci terpilih dan data jaringan relevan (diurutkan berdasarkan jumlah kemunculan).

Keyword	Kemunculan	Tahun Publikasi Rata-Rata	Links	Total Link Strength
Neural network	167	2014	42	130
Compressive strength	92	2015	32	85
Concrete	54	2014	25	45
Machine learning	34	2019	26	29
Modeling	32	2011	21	29
Prediction	22	2017	23	22
Support vector machine	19	2018	11	17
Deep learning	17	2019	13	13
Regression	17	2015	20	17
High performance concrete	15	2015	15	14
Fly ash	13	2014	14	12
Recycled aggregate concrete	13	2016	15	13
Elastic modulus	12	2014	15	11
Artificial intelligence	11	2016	15	9
Asphalt concrete	11	2018	6	9
Random forest	10	2019	7	7
Self-consolidating concrete	10	2013	6	8
Flexural strength	9	2018	11	9
Mixture design	9	2013	11	9
Corrosion	8	2017	9	6
Durability	8	2015	14	8
Fuzzy logic	8	2011	9	7
High strength concrete	8	2013	10	8
Mechanical properties	8	2018	11	8
Non-destructive testing	8	2015	9	8
Shear strength	8	2013	5	7
Acoustic emission	7	2017	5	6
ANFIS	7	2015	12	7
Cement mortar	7	2016	6	7
Dynamic modulus	7	2018	5	6
Genetic programming	7	2014	7	7
Reinforced concrete	7	2016	6	6
Carbonation	6	2014	10	6
Cement	6	2013	10	6
Elevated temperature	6	2017	7	5
Nano silica	6	2017	7	5
Optimization	6	2014	12	6
Porosity	6	2015	7	6
Silica fume	6	2014	9	6
Strength	6	2011	9	4
Bond strength	5	2015	5	5
Geopolymer	5	2017	5	5
Image processing	5	2017	6	5
Microstructure	5	2015	6	5
Slag	5	2011	7	5

ANFIS = Sistem inferensi neuro-fuzzy adaptif.

Gambar 8.3 dan Tabel 8.1 juga menunjukkan bahwa minat penelitian telah difokuskan pada prediksi sifat-sifat beton setelah pengerasan, termasuk kuat tekan, modulus elastisitas, kuat lentur, kuat geser, kuat lekat, modulus dinamis, porositas, dan durabilitas (misalnya, korosi dan karbonasi). Namun, pemodelan kinerja beton dalam keadaan segar masih kurang dipelajari oleh teknik AI. Hal ini harus menjadi perhatian para peneliti beton, mengingat sifat-sifat beton segar, seperti pengerasan, bleeding, segregasi, evolusi panas, penyusutan plastis, dan sifat reologi, juga penting untuk kemampuan kerja dalam praktik konstruksi dan pengembangan mikrostruktur menuju kinerja beton setelah pengerasan (misalnya, kekuatan dan durabilitas).

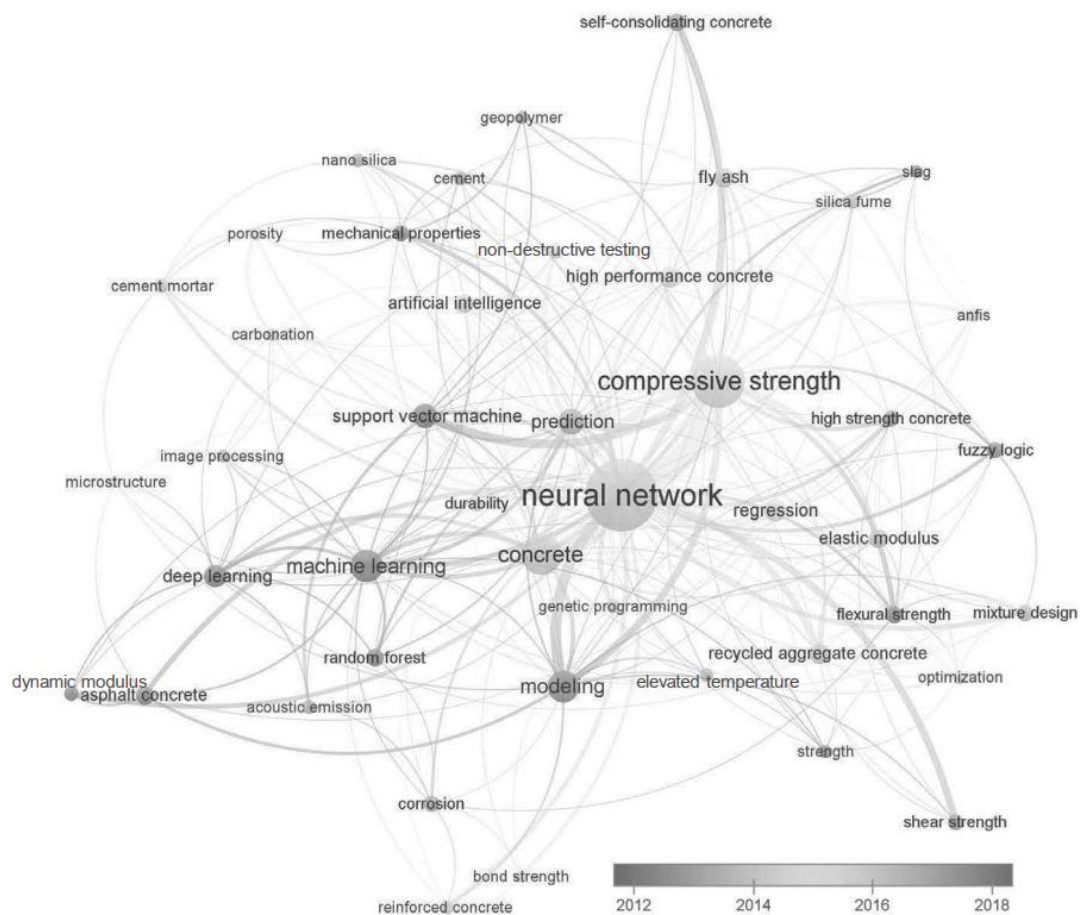
Salah satu tantangan utama yang menghambat aplikasi praktis AI dalam prediksi sifat beton segar adalah kurangnya kumpulan data yang besar dan universal untuk sifat beton segar. Misalnya, nilai absolut (misalnya, tegangan luluh dan viskositas plastis) yang dihitung untuk campuran beton tertentu tidak identik dan tidak dapat dibandingkan di antara berbagai rheometer (dengan prinsip dan geometri yang berbeda). Dengan demikian, pengumpulan data dari berbagai laboratorium menggunakan rheometer yang berbeda dapat menjadi kurang bermakna. Ke depannya, akan menjanjikan untuk menstandarisasi bahan referensi untuk rheometri beton guna mengkalibrasi berbagai rheometer beton dan menormalkan nilai yang dihitung. Dengan pengembangan kumpulan data yang besar untuk properti baru dan ketersediaan teknik AI, prediksi dan pemodelan perilaku beton yang akurat sejak dini dapat sangat berguna.

Berdasarkan jaringan tersebut, pengamatan serupa dapat dilakukan untuk berbagai jenis beton. Di antara berbagai jenis beton, beton kinerja tinggi, beton agregat daur ulang, beton aspal, beton self-consolidating, beton mutu tinggi, beton bertulang, dan beton geopolimer telah banyak dilaporkan dengan metode AI (lihat Gambar 8.3 dan Tabel 8.1). Tidak adanya jenis beton lain dalam jaringan, termasuk beton sebelumnya, beton agregat ringan, dan beton cetak 3D, menunjukkan bahwa jenis beton ini telah diabaikan dalam penelitian beton terkait AI. Teknologi AI telah menunjukkan potensinya yang besar untuk menawarkan pendekatan baru untuk memodelkan dan memprediksi perilaku material sebagian besar beton. Penelitian saat ini dapat diperluas untuk mengeksplorasi jenis beton lain dengan menggunakan pendekatan AI, yang dapat memfasilitasi pengembangan ekosistem intelijen untuk berbagai material beton.

Seperti yang ditunjukkan pada Gambar 8.3, simpul dengan warna yang sama menunjukkan topik yang serupa di antara publikasi, dan tujuh kluster kata kunci yang berbeda diperoleh dalam jaringan. Dari setiap kluster, minat penelitian utama dan kesenjangan penelitian dapat diidentifikasi. Misalnya, dalam kluster kuning (Gambar 8.3, tengah kanan), kata kunci seperti "kekuatan", "kekuatan tekan", "kekuatan lentur", "modulus elastisitas", dikelompokkan bersama dengan "desain campuran" dan "optimasi". Hal ini menunjukkan bahwa ukuran kinerja fisik beton telah menjadi tujuan utama optimasi desain campuran. Namun, desain campuran beton melibatkan beberapa kriteria yang saling bersaing, seperti meminimalkan biaya dan dampak lingkungan (misalnya, emisi karbon) sekaligus memaksimalkan kinerja fisik. Dari sudut pandang aplikasi rekayasa, diperlukan upaya

penelitian lebih lanjut untuk mengeksplorasi penerapan teknik AI dalam permasalahan multi-objektif menuju beton yang lebih murah, lebih kuat, lebih mudah dikerjakan, lebih tahan lama, dan lebih ramah lingkungan.

Gugus hijau adalah gugus lain dengan ukuran signifikan pada Gambar 8.3. Gugus ini terdiri dari kata kunci seperti "pembelajaran mesin", "pembelajaran mendalam", dan "pemrosesan gambar". Perlu ditunjukkan bahwa topik-topik ini dianggap baru, seperti yang ditunjukkan pada Gambar 8.4. Berbeda dengan representasi statis domain pengetahuan pada Gambar 8.3, jaringan pada Gambar 8.4 memberikan tampilan garis waktu peta pengetahuan, di mana evolusi aplikasi AI dalam domain konkret dapat divisualisasikan menurut tahun publikasi rata-rata setiap kata kunci.



Gambar 8.4: Jaringan kata kunci yang muncul bersamaan terkait penelitian AI dalam material beton (tampilan linimasa).

Khususnya, tahun publikasi rata-rata kata kunci "pembelajaran mendalam" adalah 2019, yang menunjukkan bahwa penekanan penelitian telah bergeser ke arah aplikasi teknik pembelajaran mendalam dalam sains konkret, terutama untuk analisis gambar dan pengenalan data (yang masing-masing sesuai dengan kata kunci "pemrosesan gambar" dan "emisi akustik"). Hal ini dapat dikaitkan dengan keberhasilan arsitektur pembelajaran mendalam yang dikembangkan dalam ilmu komputer, termasuk jaringan saraf tiruan

konvolusional untuk klasifikasi citra dan jaringan memori jangka pendek panjang untuk pemodelan deret waktu.

Perlu dicatat bahwa teknik pembelajaran mendalam terutama digunakan untuk deteksi retakan dalam praktik lapangan, sedangkan integrasi teknik-teknik ini dengan analisis petrografi konkret (misalnya, pemindaian alas datar, mikroskop elektron pemindaian, dan tomografi terkomputasi sinar-X) dapat menjanjikan namun masih kurang diteliti. Kata kunci seperti "jaringan saraf", "kekuatan tekan", dan "beton" terwakili dalam spektrum menengah sekitar tahun 2015 (lihat Gambar 8.4 dan Tabel 8.1).

Hal ini karena topik-topik tersebut telah menjadi fokus penelitian selama periode waktu yang diteliti. Model AI termasuk mesin vektor pendukung (rata-rata tahun publikasi: 2018) dan hutan acak (rata-rata tahun publikasi: 2019) telah menjadi lazim di samping pendekatan pembelajaran mendalam, yang menunjukkan bahwa lebih banyak upaya penelitian telah dilakukan baru-baru ini untuk mengeksplorasi efektivitas teknik AI (selain jaringan saraf) dalam penelitian beton.

8.4 POLA SITASI: ANALISIS KO-SITASI DOKUMEN


Sebuah publikasi biasanya menyertakan daftar referensi, yang menggambarkan basis pengetahuan publikasi tersebut. Serupa dengan ko-okurensi, ko-sitasi dapat didefinisikan sebagai frekuensi dua referensi yang dikutip bersama oleh publikasi lain. Mengingat bahwa referensi yang sering dikutip biasanya menyajikan konsep, metode, atau kesimpulan kunci dalam suatu bidang penelitian, pola ko-sitasi referensi dapat memberikan wawasan berharga tentang hubungan antara ide-ide kunci ini. Analisis ko-sitasi dokumen telah menunjukkan potensinya untuk mengungkap struktur intelektual literatur ilmiah dan dengan demikian mengidentifikasi minat penelitian dan tren yang muncul dalam suatu domain penelitian.

Untuk mengidentifikasi lebih lanjut tren penelitian dalam AI dan studi konkret, jaringan ko-sitasi dokumen dihasilkan oleh CiteSpace (lihat Gambar 8.5). Catatan dari 389 publikasi yang mengutip dan 11.842 referensi yang dikutip diambil dari WoS, seperti yang dijelaskan dalam Bagian 8.2. Pada Gambar 8.5, setiap simpul mewakili referensi yang dikutip, dan ukuran simpul mencerminkan nomor kutipan referensi tersebut. Tautan antar simpul menunjukkan ko-kutipan. Warna tautan ini mewakili pertama kalinya ketika dua referensi dikutip bersama. Tautan dalam beberapa tahun terakhir ditunjukkan dengan warna merah, sedangkan tautan ko-kutipan yang lebih lama diwarnai dengan warna kuning.

Tidak ada pemangkasan jaringan (atau pengurangan tautan) yang dilakukan untuk menghindari pengurangan karakteristik jaringan bibliografi. Gambar 8.5 dan Tabel 8.2 menunjukkan lima klaster utama yang diidentifikasi dalam jaringan. Klaster-klaster ini diberi nomor dan diberi peringkat berdasarkan ukurannya, yaitu, jumlah referensi dalam satu klaster.

Setiap klaster diberi label menggunakan algoritma rasio log-likelihood. Algoritma ini mengidentifikasi label berdasarkan analisis semantik laten dari publikasi yang mengutip referensi di setiap klaster. Meskipun pendekatan ini terbukti memberikan hasil paling akurat dalam hal pelabelan unik dan cakupan yang memadai, pemeriksaan manual tambahan

terhadap publikasi dilakukan untuk memvalidasi silang label yang diidentifikasi dan menentukan fokus setiap kluster.



Gambar 8.5: Jaringan dokumen yang dikutip bersama dalam publikasi tentang AI pada material beton (tampilan linimasa).

Tabel 8.2: Kluster utama yang teridentifikasi dalam analisis kutipan bersama dokumen.

Cluster ID	Size	Silhouette Value	Average Publication Year	Cluster Label	Focus of the Cluster
1	169	0.913	2011	Kekuatan beton	Kekuatan tekan beton
2	65	0.957	1996	Memprediksi sifat	Desain campuran
3	47	0.979	2002	Menggunakan jaringan saraf tiruan	Jaringan saraf tiruan; durabilitas
4	47	0.952	2002	Daya dukung beban	Kapasitas geser; modulus elastisitas
5	46	0.976	1997	Pasta semen	Pasta semen; pemadatan limbah solidification

Dua metrik fundamental, yaitu indeks Q modularitas dan nilai siluet, dihitung untuk memeriksa keandalan jaringan. Indeks Q modularitas berkisar dari 0 hingga 1 dan menilai sejauh mana jaringan dapat dipartisi menjadi beberapa kluster; nilai siluet berkisar antara -1 dan 1 dan mengukur kualitas konfigurasi pengelompokan. Indeks Q modularitas yang lebih tinggi dan nilai siluet yang lebih tinggi menyiratkan pembagian jaringan yang lebih tinggi dan homogenitas kluster yang lebih baik, masing-masing.

Ambang batas nilai siluet ditemukan sebesar 0,7, di atas nilai tersebut kluster dalam jaringan dapat dianggap sangat terisolasi dengan batas yang jelas dan hubungan yang lemah antara kluster individu. Jaringan pada Gambar 8.5 memiliki indeks Q modularitas sebesar 0,8867 dan nilai siluet rata-rata tertimbang sebesar 0,9557. Nilai-nilai ini relatif tinggi, menunjukkan bahwa jaringan tersebut sangat terbagi menjadi kluster, yang masing-masing, secara rata-rata, sangat homogen. Dengan kata lain, studi di setiap kluster yang teridentifikasi konsisten dalam membahas isu-isu serupa.

Sesuai ukuran klaster pada Tabel 8.2, klaster #1 pada kekuatan beton merupakan klaster terbesar dengan 169 referensi. Setelah memeriksa isi dari 47 publikasi yang mengutip referensi ini, fokus klaster ini dapat ditentukan lebih lanjut sebagai kekuatan tekan beton. Hal ini sejalan dengan pengamatan sebelumnya pada Gambar 8.3 dan Tabel 8.1, di mana "kekuatan tekan" merupakan kata kunci kedua yang paling sering digunakan. "Tahun publikasi rata-rata" pada Tabel 8.2 menunjukkan periode rata-rata di mana referensi dalam klaster tertentu diterbitkan.

Meskipun sebagian besar klaster menunjukkan aktivitas lebih dari dua dekade lalu (yaitu, 1996–2002), studi dalam klaster #1 telah dipublikasikan baru-baru ini, rata-rata sekitar tahun 2011, dan klaster ini memiliki durasi aktif terpanjang, yaitu sekitar 17 tahun, dari tahun 2002 hingga 2019. Hal ini kembali menegaskan signifikansi klaster #1 terhadap kuat tekan beton di bidang AI dalam ilmu beton. Deteksi lonjakan sitasi dilakukan lebih lanjut untuk mengidentifikasi referensi yang sangat signifikan bagi domain beton. Lonjakan sitasi terjadi ketika sebuah referensi menerima lonjakan yang cukup besar dalam hal sitasi dan perhatian dalam durasi tertentu (Chen dkk., 2010) (misalnya, simpul besar pada Gambar 8.5). Tabel 8.3 menunjukkan 10 referensi teratas dengan kekuatan lonjakan tertinggi (yaitu, referensi yang paling banyak dikutip bersama dan berpengaruh).

Menarik untuk dicatat bahwa semua referensi yang tercantum dalam Tabel 8.3 dikelompokkan dalam klaster #1. Sebagian besar berfokus pada prediksi numerik kuat tekan, dan hanya dua referensi yang berfokus pada modulus elastisitas (yang berkorelasi dengan kuat tekan). Semua referensi ini menggunakan teknik AI untuk prediksi. Sesuai dengan Bagian 8.3, jaringan saraf tiruan merupakan algoritma yang paling umum digunakan. Jenis beton yang diteliti dalam studi-studi ini bervariasi, mulai dari beton normal hingga beton kinerja tinggi dan beton agregat daur ulang. Perlu dicatat bahwa sebagian besar dari 10 referensi yang dikutip ini telah tercakup dalam basis data bibliografi yang berisi 389 publikasi yang mengutip, yang melakukan validasi silang atas kelengkapan dan representasi basis data yang diperoleh.

Tabel 8.3: 10 rujukan teratas mengenai AI pada material konkret dengan ledakan ko-sitasi dokumen terkuat.

No	Referensi	Kekuatan Ledak (Burst Strength)	Tahun	Mulai	Akhir	Rentang (Span)	Jumlah Sitasi	ID Kluster
1	Duan et al. (2013a)	11.27	2013	2015	2020	5	29	1
2	Öztaş et al. (2006)	10.15	2006	2008	2013	5	24	1
3	Sobhani et al. (2010)	7.84	2010	2012	2018	6	22	1
4	Behnood et al. (2017)	7.76	2017	2017	2020	3	15	1
5	Pala et al. (2007)	7.66	2007	2011	2016	5	16	1

6	Behnood et al. (2015)	7.59	2015	2018	2020	2	18	1
7	Topçu dan Saridemir (2008)	7.38	2008	2016	2020	4	16	1
8	Chithra et al. (2016)	7.31	2016	2017	2020	3	16	1
9	Dantas et al. (2013)	7.07	2013	2008	2013	5	17	1
10	Duan et al. (2013b)	6.12	2013					

Tabel 8.4: 10 publikasi yang paling banyak dikutip mengenai AI dalam material beton.

No	Referensi	Tahun	Judul	Jumlah Kutipan
1	Ya (1998b)	1998	Pemodelan kekuatan beton berkinerja tinggi menggunakan jaringan saraf tiruan	548
2	Gopalakrishnan dkk. (2017)	2017	Jaringan Saraf Konvolusional Dalam dengan pembelajaran transfer untuk deteksi kerusakan perkerasan jalan berbasis data visi komputer	254
3	Ni dan Wang (2000)	2000	Prediksi kekuatan tekan beton dengan jaringan saraf	243
4	Öztaş dkk. (2006)	2006	Memprediksi Kekuatan Tekan dan Slump Beton Mutu Tinggi Menggunakan Jaringan Syaraf Tiruan	212
5	Ya (2007b)	2007	Pemodelan aliran slump beton menggunakan regresi orde kedua dan jaringan saraf tiruan	163
6	Duan dkk. (2013a)	2013	Prediksi kuat tekan beton agregat daur ulang menggunakan jaringan saraf tiruan	152
7	Sobhani dkk. (2010)	2010	Prediksi Kekuatan Tekan Beton Tanpa Slump: Studi Perbandingan Model Regresi, Jaringan Syaraf Tiruan dan ANFIS	152
8	Dorafshan dkk. (2018)	2018	Perbandingan jaringan saraf konvolusional dalam dan detektor tepi untuk deteksi retakan berbasis gambar pada beton	150
9	Alshihri dkk. (2009)	2009	Jaringan saraf untuk memprediksi kekuatan tekan beton ringan struktural	138
10	Tam dkk. (2007)	2007	Optimasi proporsi agregat daur ulang dalam beton menggunakan pendekatan pencampuran dua tahap	135

Tabel 8.4 menyajikan informasi sitasi dari 389 publikasi terkait AI dalam beton. Tiga studi terdapat pada Tabel 8.3 dan Tabel 8.4, yang menunjukkan pentingnya studi-studi tersebut dalam bidang penelitian beton. Sebagaimana ditunjukkan pada Tabel 8.2, klaster #2 dengan 65 referensi yang disitasi diidentifikasi sebagai "properti prediksi". Terdapat delapan publikasi yang disitasi dalam klaster ini dengan fokus pada desain campuran.

Sebagian besar penelitian menekankan analisis sensitivitas kekuatan untuk menyelidiki pengaruh komponen campuran, seperti semen, air, silika fume, dan abu terbang. Analisis sensitivitas tersebut dapat mengidentifikasi hubungan antara kekuatan dan masing-masing

komponen campuran beton. Namun, sebagaimana telah disebutkan sebelumnya, kebutuhan akan campuran beton untuk memenuhi berbagai tujuan dan kriteria desain semakin meningkat. Dengan demikian, pengembangan model AI yang tepat untuk optimasi multi-tujuan (misalnya, optimasi kekuatan-biaya-CO₂) akan berkontribusi pada industri beton.

Klaster #3 secara otomatis diberi label "menggunakan jaringan saraf tiruan". Pemeriksaan manual terhadap lima publikasi yang dikutip mengonfirmasi bahwa model jaringan saraf tiruan digunakan dalam studi-studi ini. Hal ini menunjukkan peran kunci jaringan saraf tiruan dalam penelitian beton, yang sepenuhnya sesuai dengan pengamatan di Bagian 8.3. Fokus lain dari klaster ini adalah durabilitas, seperti karbonasi, penetrasi klorida, kuat tekan lanjut usia, dan kekuatan sisa setelah suhu tinggi.

Klaster terbesar keempat dengan 47 referensi yang dikutip, klaster #4, diidentifikasi sebagai "kapasitas menahan beban", yang bukan merupakan penandaan yang jelas. Kami meninjau konten dari enam publikasi dalam klaster ini dan mengidentifikasi kapasitas geser atau modulus elastisitas sebagai fokus. Klaster #5 yang diberi label sebagai "pasta semen" memiliki 46 referensi yang dikutip tetapi hanya dua artikel yang mengutip.

Kedua studi ini menyelidiki efek senyawa logam anorganik murni atau beracun pada kekuatan tekan dan waktu pengikatan dari sistem pasta semen dengan model jaringan saraf, memberikan manfaat finansial dan solusi ramah lingkungan untuk pengolahan limbah industri dengan pemadatan berbasis semen. Oleh karena itu, fokus klaster ini dapat berupa pasta semen atau pemadatan limbah. Dibandingkan dengan klaster lain, klaster #5 merupakan klaster terkecil, yang menyiratkan relatif sedikit perhatian yang diberikan pada topik penelitian ini sejauh ini.

Perhatikan bahwa semua nilai siluet tinggi pada Tabel 8.2 lebih besar dari ambang batas 0,7, yang menunjukkan bahwa setiap klaster sangat terisolasi dan terputus-putus satu sama lain dengan hubungan yang lemah di antaranya (lihat Gambar 8.5). Hal ini menyoroti fakta bahwa para peneliti tidak mengutip karya yang relevan di luar klaster mereka, dan dengan demikian gagal memanfaatkan beragam sumber pengetahuan (Darko dkk., 2020; Nerur dkk., 2008). Akibatnya, badan penelitian AI saat ini dalam domain konkret tampak berorientasi ke dalam, tidak mendapatkan manfaat dari teori atau konsep yang berlaku dari domain penelitian lain (Hosseini dkk., 2018). Karena AI sendiri merupakan konsep dari bidang ilmu komputer, penelitian interdisipliner diharapkan dapat memperluas batas pengetahuan di bidang konkret.

8.5 PEMBAHASAN DAN TREN MASA DEPAN

Teknik AI telah memasuki ranah sains beton pada awal 1990-an dan peningkatan eksponensial dalam publikasi relevan telah terlihat sejak dekade terakhir (Gambar. 8.2). Tren ini menegaskan meningkatnya minat penelitian AI di bidang material beton. Literatur yang ada (periode: 1990–2020) tentang AI dalam material beton telah dikaji pada bagian sebelumnya menggunakan perangkat scientometrik, termasuk analisis ko-okurensi kata kunci (Bagian 8.3) dan analisis ko-sitasi dokumentasi (Bagian 8.4).

Analisis scientometrik memperluas studi tinjauan sebelumnya di bidang ini dengan memberikan interpretasi kuantitatif dari struktur pengetahuan masa lalu dan masa kini serta

menawarkan gambaran dan pemahaman yang lengkap tentang literatur AI dalam domain beton. Sebagian besar upaya penelitian diarahkan pada prediksi sifat beton, khususnya kuat tekan, dan keberhasilan substansial telah dicapai melalui penggunaan model jaringan saraf tiruan. Misalnya, karya Yeh (1998b) yang paling banyak dikutip (Tabel 8.4) menggunakan model jaringan saraf tiruan pada kumpulan data lebih dari 1.000 sampel untuk memprediksi kuat tekan beton berkinerja tinggi, dan memperoleh koefisien determinasi (R^2) yang tinggi, yaitu sekitar 0,91 hingga 0,92.

Model jaringan saraf tiruan ini, dengan masukan berupa konstituen campuran beton, secara signifikan mengungguli analisis regresi tradisional yang hanya didasarkan pada rasio air terhadap semen dan usia ($R^2 \approx 0,57$). Sejak saat itu, pendekatan jaringan saraf tiruan telah menerima perhatian terbesar untuk memprediksi sifat-sifat berbagai jenis beton. Pada bagian ini, kami menyajikan perspektif kami tentang tantangan dan peluang utama dalam domain AI dalam ilmu beton berdasarkan hasil yang disajikan sebelumnya.

Data

Sebagaimana dibahas pada Bagian 8.3, upaya penelitian yang ada berfokus pada prediksi sifat pengerasan material beton, sementara pemodelan perilaku beton dalam keadaan segar kurang mendapat perhatian dalam literatur terkini. Hal ini dapat dikaitkan dengan kesulitan dalam menyusun kumpulan data untuk sifat beton segar mengingat prinsip dan hasil pengukuran bervariasi di antara metode atau instrumen pengujian (misalnya, rheometer).

Pemeriksaan lebih lanjut terhadap 389 publikasi yang diperoleh menunjukkan bahwa sebagian besar penelitian sangat bergantung pada kumpulan data kecil dengan kurang dari 200 titik data eksperimen, yang mungkin tidak memadai untuk teknik AI, terutama model jaringan saraf dengan sejumlah besar parameter yang harus dikalibrasi, dan dapat menyebabkan overfitting model AI dan kinerja generalisasi yang buruk pada kumpulan data baru. Kurangnya dataset yang besar dan universal untuk material beton menjadi tantangan besar menuju adopsi AI yang lebih luas dalam industri konstruksi. Puluhan ribu campuran beton serta sifat fisiknya telah dilaporkan dalam literatur, tetapi mengumpulkan data ini bisa menjadi masalah penambangan data yang menakutkan.

Artikel penelitian ditulis dalam format yang berbeda oleh para peneliti di laboratorium yang berbeda, menggunakan parameter eksperimen yang berbeda; metode dan hasil disajikan dengan istilah yang berbeda dengan tingkat kelengkapan yang tidak konsisten; dengan demikian, ekstraksi data secara manual dari literatur bisa jadi agak memakan waktu dan padat karya. Selain itu, hasil nol atau negatif cenderung dibuang dan tidak dipublikasikan, meskipun hasil ini akan sangat berguna dalam konteks AI. Hal ini mengarah pada seruan untuk standarisasi kriteria pelaporan data dan berbagi data penelitian, yang merupakan langkah besar menuju sains terbuka.

Terdapat pula pendekatan lain yang layak dieksplorasi ketika menangani masalah kelangkaan data. Salah satu topik yang menjanjikan namun kurang diteliti dalam penelitian beton adalah pembelajaran transfer, di mana pengetahuan yang dipelajari dari satu material atau properti dapat digunakan untuk mengembangkan model untuk material atau properti

serupa. Sebagaimana dibahas di Bagian 8.3, literatur yang ada terutama berfokus pada jenis beton tertentu (misalnya, beton kinerja tinggi) dan properti beton (misalnya, kuat tekan).

Oleh karena itu, wajar untuk berasumsi bahwa lebih banyak kumpulan data terkait jenis beton dan properti ini tersedia. Dengan menggunakan pembelajaran transfer, model yang andal dapat dikembangkan untuk jenis beton lain atau properti lain yang kurang mendapat perhatian karena hanya tersedia sedikit data. Solusi lain untuk mengatasi kelangkaan data adalah mengekstraksi kumpulan data komposisi-properti melalui pendekatan pemrosesan bahasa alami atau penambangan teks.

Data biasanya disajikan dalam bentuk tidak terstruktur dalam artikel penelitian: peneliti dapat melaporkan komposisi campuran beton dalam satu tabel, kondisi pengujian dan parameter eksperimen dalam teks utama bagian metode, dan kemudian properti akhir dalam gambar di bagian hasil. Mengingat sifat data yang sangat terdistribusi, penambangan informasi otomatis dari literatur dapat lebih efektif dan andal daripada pengumpulan manual, meskipun belum ada penelitian yang mencoba menerapkan pendekatan ini dalam ranah beton.

Model

Model jaringan saraf tiruan telah banyak digunakan dalam literatur beton terkini (lihat Bagian 8.3 dan 8.4). Keberhasilan model jaringan saraf tiruan dalam penelitian beton memberikan gambaran sekilas tentang kemungkinan aplikasi di masa mendatang. Tren yang sedang berkembang adalah pengembangan dan penerapan jaringan saraf tiruan konvolusional, kelas populer jaringan saraf tiruan dalam atau pembelajaran mendalam. Jaringan dalam di sini mengacu pada jaringan saraf tiruan dengan arsitektur yang lebih dalam dan lebih banyak lapisan pemrosesan. Tabel 8.4 menyajikan dua artikel penelitian yang termasuk dalam publikasi yang paling banyak dikutip dan sangat berkaitan dengan aplikasi jaringan saraf tiruan konvolusional.

Kedua studi ini telah menunjukkan keunggulan penggunaan jaringan saraf tiruan konvolusional untuk deteksi retakan dalam praktik lapangan, misalnya, pada jembatan beton dan perkerasan jalan. Hal ini dapat dikaitkan dengan akurasi tinggi jaringan saraf tiruan konvolusional dalam memproses data dengan pola grid, misalnya, gambar. Meskipun teknik-teknik ini telah dieksplorasi untuk memantau struktur beton pada skala makro, studi tentang aplikasinya dalam analisis mikrostruktur beton (misalnya, mikroskop elektron pemindaian dan tomografi terkomputasi sinar-X) masih terbatas, yang memungkinkan dihasilkannya sejumlah besar gambar dan membutuhkan upaya ekstensif dari para peneliti untuk mengelola dan menginterpretasikannya. Banyak model AI telah diperlakukan sebagai "kotak hitam" dalam penelitian konkret, terutama untuk jaringan saraf yang seringkali memberikan prediksi akurat dengan mengorbankan kompleksitas model yang tinggi. Salah satu tantangan yang menghambat adopsi sistematis mereka dalam industri konstruksi adalah kurangnya interpretabilitas dalam model AI. Upaya penelitian yang terbatas telah dicurahkan untuk mengungkap bagaimana atau mengapa suatu model memprediksi seperti itu (yaitu, hubungan sebab-akibat).

Selain membangun model yang akurat, penting untuk mendapatkan wawasan dan pengetahuan dari model dalam domain konkret. Hipotesis yang dapat diuji yang dihasilkan

dari model yang dapat diinterpretasikan dapat divalidasi silang melalui eksperimen yang diusulkan. Interpretabilitas telah menjadi bidang penelitian yang aktif dalam ilmu komputer. Ke depannya, model AI yang menawarkan pemahaman ilmiah akan semakin diminati dalam bidang penelitian konkret. Penelusuran mendalam terhadap literatur beton yang diperoleh mengungkapkan bahwa sebagian besar penelitian AI didasarkan pada model AI yang umum diakses dengan penekanan utama pada penyetelan parameter. Karena model-model ini dirancang untuk tujuan penambangan data, model-model ini membutuhkan kumpulan data yang besar dan sangat bergantung pada informasi yang terkandung dalam data tersebut tanpa mempertimbangkan prinsip-prinsip ilmiah yang telah diketahui.

Hal ini menimbulkan tantangan karena kurangnya data yang tersedia dalam ilmu beton (dibahas di Bagian 5.1). Kemajuan terbaru dalam ilmu data yang dipandu fisika telah menggambarkan potensi integrasi hukum fisika yang telah diketahui atau pengetahuan ilmiah (misalnya, hubungan terbalik antara kuat tekan dan rasio air terhadap semen dalam konteks penelitian beton) dengan model AI. Pendekatan semacam itu menawarkan solusi baru untuk meningkatkan interpretabilitas model, meningkatkan kinerja generalisasi, dan mengurangi jumlah data yang dibutuhkan untuk pelatihan.

8.6 KESIMPULAN

AI telah digunakan dalam penelitian beton selama hampir tiga dekade, dan telah memajukan pemodelan numerik serta prediksi sifat beton. Bab ini telah mengkaji literatur yang ada menggunakan pendekatan scientometrik seperti analisis ko-okurensi kata kunci dan analisis ko-sitasi dokumen. Hasil penelitian menunjukkan bahwa minat penelitian saat ini berfokus pada penerapan model jaringan saraf tiruan dalam prediksi kuat tekan beton, sementara teknik AI lainnya serta pengukuran fisik lainnya masih kurang dipelajari.

Hal ini menyiratkan bahwa penelitian AI yang ada dalam ilmu beton masih belum matang, dengan kekuatan penggabungannya yang masih jauh dari sepenuhnya terwujud. Dengan kemajuan berkelanjutan dalam data (misalnya, standardisasi pelaporan, berbagi data, transfer pengetahuan melalui pembelajaran transfer, dan pengumpulan data otomatis melalui pemrosesan bahasa alami atau penambangan teks) dan model (misalnya, arsitektur yang lebih mendalam, interpretabilitas yang lebih tinggi, dan lebih memahami fisika), ekosistem kecerdasan yang sesungguhnya sedang berkembang dalam ilmu beton dan akan berdampak besar pada bidang ini.

BAB 9

KEANDALAN KRIGING UNTUK PENILAIAN KEAMANAN STRUKTURAL

9.1 PENDAHULUAN

Keandalan struktural berkaitan dengan evaluasi keamanan secara probabilistik dengan mempertimbangkan keacakan inheren dalam respons struktural dan beban yang diterapkan. Keandalan struktural telah digunakan secara historis dalam kalibrasi kode dan standar desain struktural dengan mengikuti pendekatan desain keadaan batas, di mana resistansi terfaktor harus sama dengan atau lebih besar dari beban terfaktor. Salah satu alasan utama yang menghambat meluasnya penggunaan analisis keandalan oleh insinyur struktur dalam desain dan penilaian struktur, dibandingkan dengan kalibrasi kode, adalah kurangnya perangkat komputer yang andal yang dirancang untuk menilai keandalan interaksi struktural yang cukup kompleks seperti halnya dalam permasalahan rekayasa di dunia nyata.

Sistem struktural yang kompleks, kecerdasan buatan (AI) dapat digunakan untuk melengkapi metode keandalan yang ada untuk mengevaluasi keamanan struktural. Metode berbasis kriging telah dikembangkan untuk membantu mengoptimalkan perhitungan keandalan dengan tujuan akhir mendorong penggunaan keandalan struktural oleh para insinyur praktisi untuk menilai keamanan sistem struktural yang kompleks. Kriging, sebagaimana dijelaskan dalam bab ini, adalah bentuk regresi stokastik yang dapat digunakan untuk mengembangkan model pengganti untuk perhitungan keandalan.

Metode ini berasal dari industri pemetaan geosains dan kemudian diterapkan pada keandalan struktural. Metode ini telah dilengkapi dengan fungsi pembelajaran untuk lebih mengoptimalkan perhitungan keandalan dan membentuk apa yang saat ini disebut sebagai Kriging pembelajaran aktif (AK), suatu bentuk AI. Tujuan utama penggunaan keandalan AK adalah untuk mengurangi biaya komputasi dalam menyelesaikan fungsi keadaan batas kompleks yang memerlukan pemanggilan teknik komputasi tingkat lanjut untuk mengkuantifikasi bagian beban dari keadaan batas, bagian resistansi, atau keduanya, bagian beban dan resistansi.

Penelitian terkait AK dalam aplikasi geoteknik lebih aktif dibandingkan dengan penggunaan AK dalam aplikasi rekayasa struktur. Meskipun kerangka dasar pelaksanaan AK tidak sensitif terhadap aplikasinya, pemilihan fungsi masukan utama bersifat spesifik kasus dan harus ditentukan berdasarkan analisis sensitivitas. Dampak penggunaan AK dalam analisis keandalan struktural disajikan dalam contoh berikut. Misalkan seorang insinyur struktur ditugaskan untuk mengkuantifikasi keandalan menara menara baja industri yang ada yang mengalami beban angin lateral. Menara menara yang ada mengalami kerusakan lokal pada sambungan dan berkurangnya ketebalan akibat korosi. Untuk mengkuantifikasi indeks keandalan struktur, insinyur perlu menetapkan model beban dan model resistansi.

Model beban dapat ditetapkan relatif mudah berdasarkan data angin historis spesifik lokasi atau statistik angin yang digunakan dalam kalibrasi kode terkait. Tidak seperti model

beban, membangun model resistansi itu rumit, terutama untuk mengevaluasi resistansi struktur yang ada dengan kerusakan lokal. Analisis numerik seperti simulasi elemen hingga (FE) biasanya digunakan untuk mengkuantifikasi resistansi global struktur yang ada dengan defisiensi lokal karena solusi bentuk tertutup mungkin tidak selalu layak. Medan acak juga dapat digunakan untuk memperhitungkan variabilitas spasial dalam resistansi material dan kerusakan akibat korosi sebagai bagian dari analisis FE.

Insinyur kini menghadapi tantangan besar, yaitu kebutuhan untuk memanggil analisis FE untuk setiap uji acak sebagai bagian dari simulasi *Monte Carlo* (MC) (yang akan dijelaskan dalam bab ini) yang digunakan untuk menyelesaikan masalah keandalan. Jumlah jalur dapat mencapai 107 untuk struktur yang sangat andal (yaitu, struktur dengan probabilitas kegagalan yang rendah). Insinyur kami menyadari bahwa memanggil analisis FE untuk setiap jalur MC bukanlah pilihan yang layak karena keterbatasan waktu setiap analisis FE dapat memakan waktu berjam-jam, tergantung pada masalahnya. Penggunaan AK untuk melakukan simulasi MC merupakan solusi ideal untuk masalah ini.

Hal ini dapat secara substansial mengurangi jumlah analisis FE yang diperlukan untuk membangun model resistansi dengan mempelajari pola hasil analisis yang diperoleh dari sekumpulan kecil model awal. Tujuan bab ini adalah untuk memberikan satu titik acuan bagi insinyur dalam contoh kita untuk melakukan analisis keandalan berbasis AK yang berfokus pada aplikasi rekayasa struktur. Bab ini dimulai dengan meninjau konsep-konsep kunci dalam keandalan struktural dan Kriging, diikuti dengan penyajian Kriging biasa, dan simulasi MC AK. Bab ini diakhiri dengan tiga contoh praktis penerapan AK dalam masalah rekayasa struktur.

9.2 KONSEP KUNCI ANALISIS KEANDALAN

Pada bagian ini, konsep kunci analisis keandalan menggunakan teknik pembelajaran aktif akan diperkenalkan. Dasar-dasar keandalan struktural akan diuraikan, diikuti dengan ilustrasi kunci peran model pengganti dalam analisis. Konsep pendekatan pembelajaran aktif dijelaskan berdasarkan peran pengganti. Target utamanya adalah menemukan cara untuk meningkatkan efisiensi analisis keandalan menggunakan regresi nonlinier dan teknik optimasi.

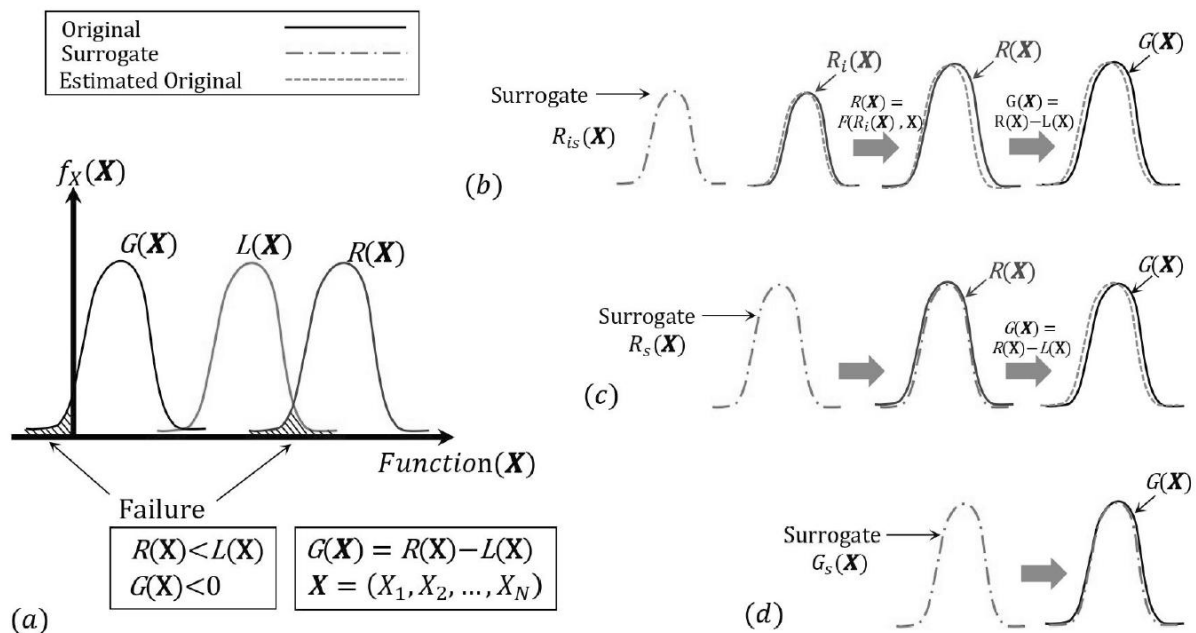
Analisis berbasis keandalan dalam rekayasa struktur membahas probabilitas kegagalan suatu struktur pada kondisi pembebanan yang ditentukan. Ketika pengaruh beban yang diberikan $[L(\mathbf{X})]$ melebihi resistansi struktur $[R(\mathbf{X})]$, kegagalan terjadi (Gambar 9.1(a)). Dalam bentuk lain, kegagalan dapat didefinisikan sebagai fungsi batas keadaan negatif (LSF), yang juga disebut fungsi kinerja $[G(\mathbf{X})]$. Fungsi kinerja yang ditunjukkan pada Gambar 9.1 didefinisikan sebagai resistansi dikurangi beban $[G(\mathbf{X}) = R(\mathbf{X}) - L(\mathbf{X})]$.

Perlu digarisbawahi bahwa fungsi kinerja ini didefinisikan untuk distribusi normal beban dan resistansi. Untuk jenis distribusi lainnya, fungsi kinerja yang berbeda dapat dibangun dengan mengubahnya menjadi distribusi normal. Vektor variabel acak yang ditunjukkan sebagai \mathbf{X} dalam bab ini adalah input untuk fungsi beban, resistansi, dan kinerja. Setiap vektor \mathbf{X} berisi serangkaian variabel acak (yaitu, X_1, X_2, \dots, X_N), yang dapat dipilih berdasarkan jenis masalah. Misalnya, dalam mencari keandalan balok beton bertulang baja (R_c), kekuatan beton (f'_c), tegangan leleh baja (f_y), tinggi batang baja dalam tarik (d), lebar

balok (b), momen akibat beban mati dan hidup (MD dan ML) dapat dianggap sebagai variabel acak, yang membentuk vektor variabel acak sebagai berikut:

$$\mathbf{X} = (X_1, X_2, X_3, X_4, X_5, X_6) = (f_c, f_y, d, b, M_D, M_L) \quad (9.1)$$

Dalam permasalahan keandalan, fungsi kinerja berkaitan dengan banyak faktor seperti perilaku dan sifat material, geometri struktur penahan, jenis beban yang diterapkan, dan variabilitas dalam sistem.



Gambar 9.1: Pemodelan pengganti dalam analisis keandalan: (a) distribusi beban dan resistansi; (b) bagian resistansi sebagai fungsi pengganti; (c) fungsi resistansi pengganti; dan (d) fungsi kinerja pengganti.

Akurasi model keandalan dapat ditingkatkan dengan memanfaatkan metode yang akurat dan canggih dalam pemodelan resistansi struktural, seperti model FE atau model beda hingga (FD), dan dengan mempertimbangkan detail sebanyak mungkin. Namun, terlepas dari kompleksitas dan kelengkapan model, terdapat kesalahan dalam pemodelan akibat ketidakpastian dalam sistem dan penyederhanaan asumsi.

Model resistansi yang ketat menyebabkan biaya komputasi yang tinggi untuk tujuan analisis keandalan, di mana jumlah panggilan yang diperlukan untuk model resistansi tinggi. Misalnya, jumlah panggilan yang diperlukan untuk menentukan probabilitas kegagalan suatu struktur dapat berkisar antara 10^5 hingga 10^{10} menggunakan MCS, yang bergantung pada jenis permasalahan dan probabilitas kegagalan yang diharapkan. Untuk mengoptimalkan analisis keandalan, biaya perhitungan dapat dikurangi dengan menggunakan model pengganti, alih-alih model yang presisi namun memakan waktu, yang disebut sebagai model asli dalam bab ini. Model asli dapat dinyatakan setidaknya dalam tiga bentuk berbeda: (1) bagian dari model

resistansi (Gambar 9.1(b)); (2) model resistansi (Gambar 9.1(c)); (3) fungsi kinerja (Gambar 9.1(d)).

Untuk beberapa model resistansi, model dapat dibagi menjadi beberapa bagian yang membutuhkan komputasi yang mahal dan murah. Model asli dapat ditetapkan sebagai bagian yang memakan waktu dan digantikan dengan model pengganti. Misalnya, analisis penampang untuk kapasitas momen balok RC memerlukan banyak iterasi untuk mencapai keseimbangan gaya dengan memvariasikan kedalaman sumbu netral. Sebagai alternatif, perhitungan kapasitas momen dapat dipisahkan menjadi beberapa bagian sederhana dengan mengetahui profil regangan dan model pengganti untuk menemukan kedalaman sumbu netral.

Seperti yang diilustrasikan pada Gambar 9.1(b), resistansi pengganti dari sebagian resistansi dapat ditemukan terlebih dahulu, diikuti dengan membangun model resistansi dan fungsi kinerja. Model asli dapat dianggap sebagai resistansi keseluruhan untuk analisis yang kompleks dan tidak dapat dipisahkan menjadi beberapa bagian. Misalnya, pemodelan FE atau FD dari elemen struktural seperti kolom beton, dinding geser, atau rangka baja dapat dianggap sebagai model pengganti, seperti yang ditunjukkan pada Gambar 9.1(c).

Selain itu, model asli dapat dianggap sebagai fungsi kinerja keseluruhan. Misalnya, sekelompok tiang pancang di dalam tanah yang menggunakan beban dan tahanan, atau struktur jembatan penuh dengan pembebanan dinamis (Gambar 9.1(d)). Semua bentuk ini menghasilkan fungsi kinerja pengganti yang memperkirakan model asli dengan biaya perhitungan yang lebih rendah. Untuk membangun model pengganti, beberapa realisasi model asli diperlukan untuk melatih model pengganti. Proses pelatihan model pengganti pada dasarnya bermanfaat dalam mengoptimalkan efisiensi biaya perhitungan dibandingkan dengan menggunakan model asli untuk analisis keandalan. Misalnya, jika analisis keandalan memerlukan 1.000 MCS yang berbeda, masing-masing orde 10^6 , total 109 panggilan untuk model asli diperlukan sementara model pengganti mungkin hanya memerlukan 105 panggilan untuk model asli, yang 10.000 kali lebih sedikit.

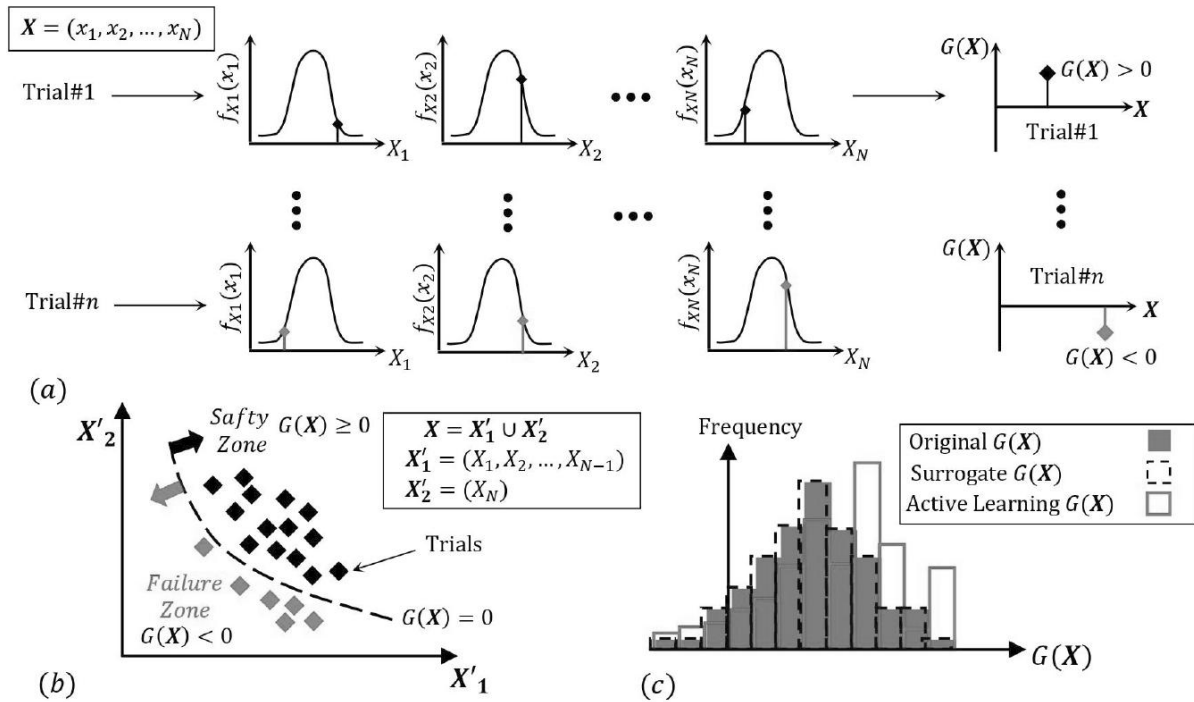
Meskipun model pengganti mengurangi biaya perhitungan, terdapat biaya yang cukup besar untuk melatih model pengganti yang mungkin memerlukan sejumlah besar panggilan untuk model asli. Oleh karena itu, beberapa metode dapat diterapkan untuk memilih basis data pelatihan menggunakan kriteria optimasi tertentu guna mengurangi biaya pelatihan, yang disebut metode pembelajaran aktif. Pembelajaran aktif membantu model pengganti dalam prosedur pelatihan dan pembaruan bolak-balik berurutan menggunakan model asli dan model pengganti. Set pelatihan awal dibangun dengan beberapa realisasi model asli, yang disebut desain eksperimen (DoE). Model pengganti dilatih menggunakan DoE ini, dan suatu fungsi dievaluasi untuk beberapa masukan menggunakan model pengganti. Fungsi yang dievaluasi disebut fungsi pembelajaran, yang menentukan titik berikutnya yang diperlukan untuk dipilih untuk pelatihan dari semua masukan yang dievaluasi.

Model asli harus digunakan untuk menemukan realisasi titik berikutnya guna memperbarui DoE. Prosedur ini diikuti dengan membangun model pengganti lain dan memperbarui DoE hingga mencapai kriteria penghentian, yang ditetapkan untuk memperoleh tingkat akurasi yang diinginkan. Prosedur ini dapat secara signifikan mengurangi jumlah

panggilan untuk model asli. Misalnya, jika untuk analisis keandalan, total 109 panggilan untuk model asli diperlukan, dan pelatihan pengganti memerlukan 105 panggilan, prosedur pembelajaran aktif mungkin hanya memerlukan 100 panggilan, yang 1.000 kali lebih sedikit daripada model pengganti tanpa pembelajaran aktif dan 107 kali lebih sedikit daripada analisis keandalan dengan model asli.

Salah satu kekurangan dalam prosedur pembelajaran aktif adalah model asli harus dipilih sebagai fungsi kinerja. Ide di balik pemilihan set data pelatihan secara selektif ini berasal dari pengoptimalan fungsi agar akurat pada nilai tertentu. Untuk analisis reliabilitas, kegagalan berkorespondensi dengan nilai tertentu (yaitu, nol) untuk fungsi kinerja. Oleh karena itu, dengan menggunakan teknik pembelajaran aktif, nilai fungsi kinerja dapat ditemukan dengan akurasi tinggi di sekitar nol, dan tanda fungsi kinerja dapat ditentukan menggunakan metode ini. Tanda fungsi kinerja cukup untuk menentukan kegagalan pada setiap percobaan menggunakan MCS untuk analisis reliabilitas.

Gambar 9.2 menunjukkan prosedur MCS dan membandingkan penggunaan teknik pembelajaran aktif, model pengganti, dan model asli. Untuk analisis MCS dengan n percobaan, di mana setiap percobaan terdiri dari N variabel acak, evaluasi percobaan ditunjukkan pada Gambar 9.2(a). Untuk setiap percobaan, nilai setiap variabel acak dapat dipilih secara acak berdasarkan jenis distribusi dan momen pertama dan kedua (yaitu, mean dan varians) dari distribusi yang sesuai, untuk membentuk vektor input unik (yaitu, X) untuk fungsi kinerja. Seperti yang ditunjukkan pada Gambar 9.2(b), evaluasi fungsi kinerja dapat dibagi menjadi dua wilayah: (1) zona aman (yaitu, $G(X) \geq 0$); dan (2) zona kegagalan (yaitu, $G(X) < 0$). Setelah fungsi kinerja dievaluasi untuk semua n percobaan, probabilitas kegagalan dapat diperoleh dengan membagi jumlah percobaan yang gagal (yaitu, n_f) dengan jumlah total percobaan (yaitu, $P_f = n_f / n$). Gambar 9.2(c) menunjukkan distribusi fungsi kinerja untuk MCS menggunakan model asli, model pengganti, dan pembelajaran aktif. Akurasi ketiga simulasi ini dalam memprediksi probabilitas kegagalan hampir sama, karena luas area fungsi kinerja negatif untuk ketiga metode (atau jumlah percobaan yang gagal) hampir sama. MCS yang menggunakan model asli dan model pengganti memiliki distribusi dan momen statistik yang sangat mirip untuk fungsi kinerja. Namun, MCS yang diperoleh melalui pembelajaran aktif tidak dapat memprediksi distribusi dan momen statistik secara akurat.



Gambar 9.2: Simulasi Monte Carlo (MCS): (a) pembangkitan uji vektor acak; (b) ilustrasi N-dimensi tereduksi dari uji; (c) pembelajaran aktif, pengganti, dan histogram asli dari fungsi kinerja.

Oleh karena itu, untuk analisis reliabilitas yang hanya berfokus pada probabilitas kegagalan, teknik pembelajaran aktif menawarkan potensi besar karena dapat memprediksi probabilitas kegagalan dengan biaya perhitungan yang jauh lebih rendah dan tingkat akurasi yang tinggi.

Namun, untuk analisis reliabilitas yang memerlukan distribusi fungsi kinerja dan momen statistiknya, model pengganti tanpa pembelajaran aktif cukup memadai. Terakhir, perlu disebutkan bahwa jika fungsi kinerja tidak kompleks dan memakan waktu, seperti fungsi linear atau fungsi nonlinier sederhana, penggunaan model asli disarankan. Dengan kata lain, model pengganti direkomendasikan jika terdapat tingkat nonlinieritas yang tinggi, atau fungsi kinerja yang kompleks dan memakan waktu perlu dievaluasi beberapa kali.

9.3 KRIGING

Kriging adalah regresi stokastik nonlinier yang ditentukan dengan meminimalkan varians respons. Untuk memprediksi respons, model harus dilatih menggunakan serangkaian masukan dan keluaran yang telah ditentukan sebelumnya, di mana setiap rangkaian masukan disebut tapak desain (S_i) dan setiap keluaran disebut respons (Y_i). Setiap tapak desain berisi vektor variabel acak berdimensi-n, dan setiap respons merupakan keluaran berdimensi-q dari model asli.

Misalnya, jika permasalahannya adalah mencari respons balok baja RC di bawah beban mati dan hidup seragam, tapak desain dapat berupa vektor yang memuat kekuatan beton (f'_c), tegangan leleh baja (f_y), tinggi batang baja tarik (d), lebar balok (b), momen akibat beban mati dan hidup (M_D dan M_L), dan respons dapat berupa vektor yang memuat kapasitas momen

ultimit (M_Q) dan lendutan balok di tengah bentang (Δ_u). Untuk contoh ini, Persamaan. 9.2 dan 9.3 masing-masing menunjukkan situs desain tunggal dan responsnya.

$$\mathbf{S}_i = [S_{i1}, S_{i2}, S_{i3}, S_{i4}, S_{i5}, S_{i6}] = [f'_c, f_y, d, b, M_D, M_L]_i; n = 6 \quad (9.2)$$

$$\mathbf{Y}_i = [Y_{i1}, Y_{i2}] = [M_Q, \Delta_u]_i; q = 2 \quad (9.3)$$

Himpunan semua lokasi desain dan responsnya yang bersesuaian disebut DoE. Perluasan Persamaan 9.2 dan 9.3 disajikan untuk kasus umum dengan m lokasi desain dan m respons masing-masing pada Persamaan 9.4 dan 9.5.

$$\mathbf{S} = \begin{bmatrix} S_{11} & \cdots & S_{1n} \\ \vdots & \ddots & \vdots \\ S_{m1} & \cdots & S_{mn} \end{bmatrix} = \begin{bmatrix} \mathbf{S}_1 \\ \vdots \\ \mathbf{S}_m \end{bmatrix}; \mathbf{S}_i = [s_{i1} \cdots s_{in}]; i = 1, \dots, m \quad (9.4)$$

$$\mathbf{Y} = \begin{bmatrix} y_{11} & \cdots & y_{1q} \\ \vdots & \ddots & \vdots \\ y_{m1} & \cdots & y_{mq} \end{bmatrix} = \begin{bmatrix} \mathbf{Y}_1 \\ \vdots \\ \mathbf{Y}_m \end{bmatrix}; \mathbf{Y}_i = [y_{i1} \cdots y_{iq}]; i = 1, \dots, m \quad (9.5)$$

di mana \mathbf{S} dan \mathbf{Y} adalah lokasi desain dan matriks respons yang masing-masing berisi m lokasi desain dan respons yang berbeda, berdimensi- n , dan berdimensi- q . Untuk set pelatihan berukuran m , respons terhadap lokasi desain pada Persamaan 9.4 dapat diperoleh menggunakan model asli untuk membangun respons seperti Persamaan 9.5. Lokasi desain dan respons dapat digunakan untuk melatih prediktor Kriging yang dapat mengestimasi respons sistem ($\hat{y}(\mathbf{X})$) untuk lokasi desain baru (\mathbf{X}) yang responsnya tidak diketahui (Persamaan 9.6), di mana respons Kriging ($\hat{y}(\mathbf{X})$) merupakan substitusi untuk respons aktual sistem ($y(\mathbf{X})$) yang dapat ditemukan menggunakan model asli.

$$\hat{y}(\mathbf{X}) : \mathbb{R}^n \rightarrow \mathbb{R}^q; \hat{y}(\mathbf{X}) = [\hat{y}_1(\mathbf{X}) \dots \hat{y}_q(\mathbf{X})]; \mathbf{X} = [X_1 \dots X_n] \quad (9.6)$$

Setiap respons yang diestimasi (yaitu, $\hat{y}_i(\mathbf{X})$, $j = 1, \dots, q$) dapat ditentukan secara terpisah, dan perhitungan untuk satu respons dapat diperluas ke semuanya. Prediktor Kriging untuk satu respons disajikan dalam Persamaan 9.7 yang terdiri dari fungsi regresi dan proses stokastik.

$$\hat{y}_j(\mathbf{X}) = \mathcal{F}(\boldsymbol{\beta}_j, \mathbf{X}) + z_j(\mathbf{X}); j = 1, \dots, q \quad (9.7)$$

di mana $\boldsymbol{\beta}_j$ adalah matriks koefisien regresi yang akan dicari oleh prediktor melalui optimasi mean squared error (MSE) prediktor, \mathcal{F} adalah fungsi regresi, dan z_j adalah proses stokastik untuk respons j (dari q). Fungsi regresi (\mathcal{F}) dapat dinyatakan sebagai kombinasi linear dari p

fungsi berbeda dengan koefisien yang tidak diketahui, seperti yang disajikan pada Persamaan 11.8.

$$\mathcal{F}(\boldsymbol{\beta}_j, \mathbf{X}) = \beta_{1j}f_1(\mathbf{X}) + \dots + \beta_{pj}f_p(\mathbf{X}) \quad (9.8)$$

di mana $f_i(\mathbf{X})$ adalah fungsi regresi i (dari p), β_{ij} adalah parameter regresi untuk fungsi regresi i (dari p), dan respons j (dari q). Format matriks Persamaan 118 ditunjukkan pada Persamaan 9.9.

$$\mathcal{F}(\boldsymbol{\beta}_j, \mathbf{X}) = [f_1(\mathbf{X}) \dots f_p(\mathbf{X})] \begin{bmatrix} \beta_{1j} \\ \vdots \\ \beta_{pj} \end{bmatrix} = \mathbf{f}(\mathbf{X})^T \boldsymbol{\beta}_j \quad (9.9)$$

di mana $\mathbf{f}(\mathbf{X})$ adalah vektor fungsi regresi yang dievaluasi pada input \mathbf{X} tertentu.

Dengan mensubstitusikan Persamaan 9.9 ke Persamaan 9.7, prediktor untuk salah satu respons (yaitu, $\hat{y}_j(\mathbf{X})$) dapat ditemukan dan disubstitusikan ke Persamaan 11.6, untuk mendapatkan format matriks umum dari prediktor (yaitu, Persamaan 9.10).

$$\hat{\mathbf{y}}(\mathbf{X}) = [\hat{y}_1(\mathbf{X}) \dots \hat{y}_q(\mathbf{X})] = [f_1(\mathbf{X}) \dots f_p(\mathbf{X})] \begin{bmatrix} \beta_{11} & \dots & \beta_{1q} \\ \vdots & \ddots & \vdots \\ \beta_{p1} & \dots & \beta_{pq} \end{bmatrix} + [z_1(\mathbf{X}) \dots z_q(\mathbf{X})] \quad (9.10)$$

Bagian regresi dari prediktor merupakan kombinasi linear dari fungsi dan koefisien yang tidak diketahui. Tiga fungsi regresi yang paling populer adalah polinomial orde nol, satu, dan dua yang disebut fungsi regresi konstan, linear, dan kuadrat, yang ditunjukkan masing-masing pada Persamaan 9.11, 9.12, dan 9.13.

$$f_1(\mathbf{X}) = 1 \quad (9.11)$$

$$f_1(\mathbf{X}) = 1; f_2(\mathbf{X}) = x_1; \dots; f_{n+1}(\mathbf{X}) = x_n \quad (9.12)$$

$$f_1(\mathbf{X}) = 1;$$

$$f_2(\mathbf{X}) = x_1; \dots; f_{n+1}(\mathbf{X}) = x_n; \quad (9.13)$$

$$f_{n+2}(\mathbf{X}) = x_1^2; \dots; f_{2n+1}(\mathbf{X}) = x_1x_n;$$

$$f_{2n+2}(\mathbf{X}) = x_2^2; \dots; f_{3n}(\mathbf{X}) = x_2x_n; \dots; f_p(\mathbf{X}) = x_n^2$$

di mana n adalah jumlah lokasi desain, dan p adalah jumlah fungsi polinomial yang dapat ditentukan menggunakan Persamaan 9.14.

$$p = \begin{cases} 1 & \text{Untuk konstan} \\ n+1 & \text{Untuk linier} \\ \frac{1}{2}(n+1)(n+2) & \text{Untuk kuadrat} \end{cases} \quad (9.14)$$

Evaluasi lokasi desain menggunakan fungsi regresi ditunjukkan dalam Persamaan 9.15 dan 9.16, yang penting untuk prediktor Kriging.


$$F = \begin{bmatrix} f(\mathcal{S}_1)^T \\ \vdots \\ f(\mathcal{S}_m)^T \end{bmatrix} = \begin{bmatrix} f_1(\mathcal{S}_1) & \cdots & f_p(\mathcal{S}_1) \\ \vdots & \ddots & \vdots \\ f_1(\mathcal{S}_m) & \cdots & f_p(\mathcal{S}_m) \end{bmatrix} = \begin{bmatrix} F_{11} & \cdots & F_{1p} \\ \vdots & \ddots & \vdots \\ F_{m1} & \cdots & F_{mp} \end{bmatrix} \quad (9.15)$$

$$F_{ij} = f_j(\mathcal{S}_i); i = 1, \dots, m; j = 1, \dots, p \quad (9.16)$$

di mana F adalah matriks berukuran m -by- p yang berisi evaluasi lokasi desain menggunakan fungsi regresi, F_{ij} adalah evaluasi fungsi regresi j untuk lokasi desain \mathcal{S}_i (seperti contoh pada Persamaan 9.2).

Konsep regresi adalah meminimalkan kesalahan estimasi dari data riil untuk data latih (yaitu, meminimalkan e). Dengan kata lain, jarak vertikal dari setiap lokasi desain yang diketahui ke fungsi regresi harus diminimalkan seperti yang ditunjukkan pada Gambar 9.3. Untuk fungsi regresi konstan, prediksi adalah rata-rata respons untuk semua lokasi desain.

Oleh karena itu, jika prediktor digunakan untuk mengevaluasi lokasi desain yang tidak diketahui, responsnya adalah nilai rata-rata terlepas dari lokasi desain [Gambar 9.3(a)]. Untuk regresi linier, nilai konstan ditambahkan ke sekumpulan fungsi linier dalam ruang n -dimensi yang berisi satu garis per lokasi desain (Gambar 9.3(b)). Untuk regresi kuadrat, sebuah konstanta ditambahkan ke sekumpulan fungsi kuadrat dalam ruang n -dimensi (Gambar 9.3(c)).



Gambar 9.3 Regresi: (a) konstan; (b) linier; (c) kuadrat.

Perbedaan antara Kriging dan regresi konvensional berkaitan dengan pemilihan fungsi galat. Untuk regresi, galat merupakan nilai deterministik, sedangkan untuk Kriging, galat merupakan proses stokastik dengan rerata nol. Vektor proses stokastik untuk semua respons q ditunjukkan pada Persamaan 9.17.

$$z(\mathbf{X}) : \mathbb{R}^n \rightarrow \mathbb{R}^q ; z(\mathbf{X}) = [z_1(\mathbf{X}) \dots z_q(\mathbf{X})]; \mathbf{X} = [X_1 \dots X_n] \quad (9.17)$$

Perlu dicatat bahwa proses stokastik juga dapat digunakan secara terpisah untuk memperkirakan respons suatu sistem. Dalam proses stokastik, respons untuk setiap lokasi desain dan setiap lokasi yang tidak diketahui yang diinginkan dianggap sebagai variabel acak. Variabel-variabel acak ini saling terkait dengan fungsi korelasi (R). Dengan kata lain, respons setiap dua lokasi desain adalah dua variabel acak yang saling berkorelasi melalui fungsi korelasi. Fungsi korelasi n-dimensi dapat dirumuskan dalam Persamaan 9.18, dengan n adalah jumlah vektor variabel masukan X (mirip dengan Persamaan 9.2).

$$R(\mathbf{L}, \mathbf{X}_i, \mathbf{X}_j) = \prod_{k=1}^n R_k(l_k, a_k, b_k); \mathbf{X}_i = [a_1 \dots a_n]; \mathbf{X}_j = [b_1 \dots b_n]; \mathbf{L} = [l_1 \dots l_n] \quad (9.18)$$

di mana R adalah fungsi korelasi, R_k adalah komponen k untuk fungsi korelasi, \mathbf{L} adalah vektor yang memuat panjang korelasi l_k (untuk $k = 1, \dots, n$), \mathbf{X}_i adalah situs n-dimensi pertama dari nilai situs a_k , dan \mathbf{X}_j adalah situs n-dimensi kedua dari nilai situs b_k . Dua fungsi korelasi yang paling populer adalah fungsi korelasi Gaussian dan Eksponensial yang masing-masing disajikan dalam Persamaan 9.19 dan 9.20.

$$R_k(l_k, a_k, b_k) = \exp\left\{-\frac{(a_k - b_k)^2}{l_k}\right\} = \exp\{-\theta_k (a_k - b_k)^2\} \quad (9.19)$$

$$R_k(l_k, a_k, b_k) = \exp\left\{-\frac{|a_k - b_k|}{l_k}\right\} = \exp\{-\theta_k |a_k - b_k|\} \quad (9.20)$$

di mana θ_k adalah parameter korelasi untuk komponen R_k dari fungsi korelasi (parameter korelasi adalah kebalikan dari panjang korelasi l_k). Contoh fungsi korelasi satu, dua, dan tiga dimensi dijelaskan lebih lanjut dalam Persamaan 9.21 hingga 9.23.

$$1D \rightarrow R(\mathbf{L}, \mathbf{X}_i, \mathbf{X}_j) = \exp\left\{-\frac{(a_1 - b_1)^2}{l_1}\right\} \quad (9.21)$$

$$2D \rightarrow R(\mathbf{L}, \mathbf{X}_i, \mathbf{X}_j) = \exp\left\{-\frac{(a_1 - b_1)^2}{l_1} - \frac{(a_2 - b_2)^2}{l_2}\right\} \quad (9.22)$$

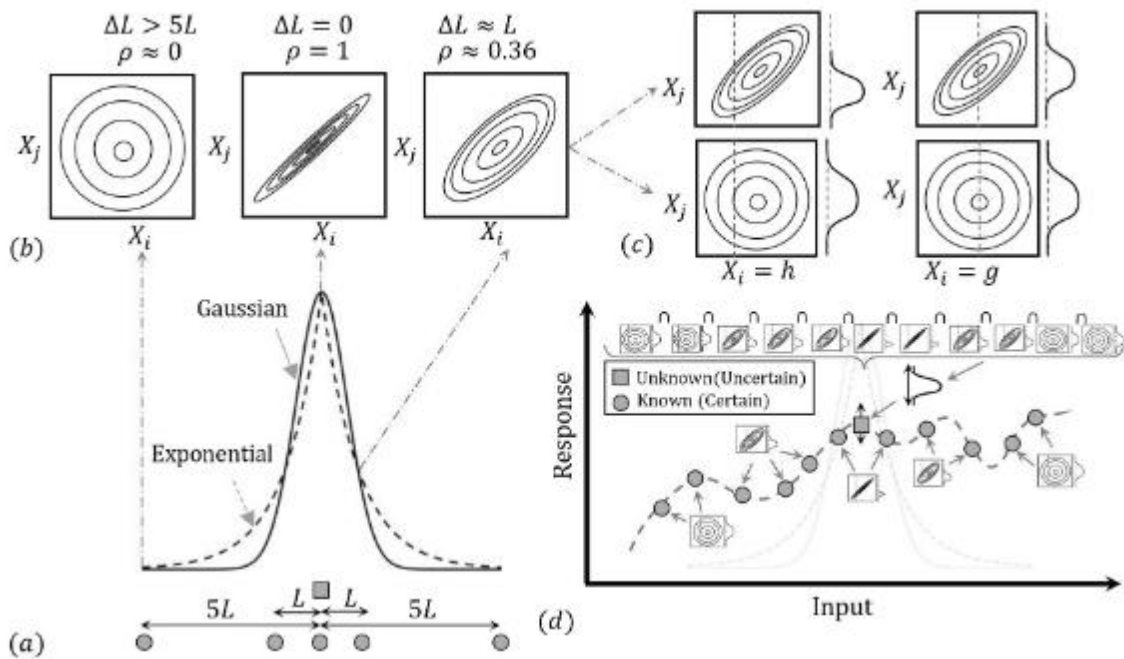
$$3D \rightarrow R(\mathbf{L}, \mathbf{X}_i, \mathbf{X}_j) = \exp\left\{-\frac{(a_1 - b_1)^2}{l_1} - \frac{(a_2 - b_2)^2}{l_2} - \frac{(a_3 - b_3)^2}{l_3}\right\} \quad (9.23)$$

Dengan mempertimbangkan permasalahan satu dimensi, estimasi lokasi yang tidak diketahui menggunakan lokasi yang telah diketahui disajikan pada Gambar 9.4. Mengenai panjang korelasi, jika jarak antara dua lokasi (yaitu, $\Delta L = a_i - b_i$) adalah nol (yaitu, $\Delta L = 0$), titik-titik tersebut berkorelasi tinggi, dan korelasinya adalah satu (yaitu, $\rho = 1$). Seiring bertambahnya

jarak antara lokasi, korelasi antara respons menurun, seperti yang disajikan pada Gambar 9.4(a).

Perlu diperjelas bahwa dimensi yang berbeda dengan satuan yang berbeda dipertimbangkan dalam lokasi n-dimensi, di mana jarak antara dua titik dalam suatu dimensi dapat dinyatakan dalam satuan panjang, waktu, gaya, atau satuan lainnya. Misalnya, dengan mempertimbangkan fungsi korelasi Gaussian dan Eksponensial untuk permasalahan satu dimensi, jika jaraknya hampir sama dengan panjang korelasi (yaitu, $\Delta L \approx l$), korelasinya akan menurun hingga hampir 0,36 (yaitu, $\rho = 0,36$), dan jika jaraknya melewati 5 kali panjang korelasi (yaitu, $\Delta L > l$), titik-titik tersebut tidak akan berkorelasi (yaitu, $\rho \approx 0$), seperti yang ditunjukkan pada Gambar 9.4(b).

Untuk evaluasi lokasi yang tidak diketahui, hanya menggunakan proses stokastik, setiap titik dianggap sebagai variabel acak yang berkorelasi dengan titik lainnya. Variabel acak yang tidak diketahui akan mengambil distribusi posterior acak menggunakan nilai-nilai tertentu dari lokasi yang diketahui, seperti yang disajikan pada Gambar 9.4(c). Estimasi lokasi yang tidak diketahui menggunakan serangkaian lokasi desain yang diketahui dengan proses stokastik memerlukan efek gabungan dari korelasi semua titik yang diketahui dengan titik yang tidak diketahui, seperti yang disajikan pada Gambar 9.4(d). Seiring bertambahnya jarak antar titik, efek titik-titik tersebut terhadap prediksi respons akan berkurang (karena korelasinya lebih rendah), seperti yang ditunjukkan pada Gambar 9.4(d).



Gambar 9.4: Proses stokastik: (a) panjang korelasi; (b) hubungan korelasi; (c) realisasi variabilitas; (d) interpolasi stokastik.

Korelasi antara setiap lokasi yang tidak diketahui yang diinginkan dan semua lokasi desain yang diketahui dapat dinyatakan dalam format vektor, seperti yang disajikan pada Persamaan 9.24.

$$\mathbf{r} = \mathbf{r}(\mathbf{L}, \mathbf{X}, \mathbf{S}) = \begin{bmatrix} r_1 \\ \vdots \\ r_m \end{bmatrix} = \begin{bmatrix} R(\mathbf{L}, \mathbf{X}, \mathbf{S}_1) \\ \vdots \\ R(\mathbf{L}, \mathbf{X}, \mathbf{S}_m) \end{bmatrix}; R(\mathbf{L}, \mathbf{X}, \mathbf{S}_i) = \prod_{k=1}^n R_k(l_k, x_k, s_{ik}); i = 1, \dots, m \quad (9.24)$$

di mana x_k dan s_{ik} masing-masing adalah komponen \mathbf{X} dan \mathbf{S}_i , dan \mathbf{r} adalah vektor korelasi yang komponen-komponennya (yaitu, r_i) adalah koefisien korelasi antara lokasi yang diinginkan (\mathbf{X}) dengan respons yang tidak diketahui dan setiap lokasi rancangan (\mathbf{S}_i) dari m lokasi rancangan. Matriks penting lainnya adalah matriks korelasi antara setiap dua lokasi rancangan, seperti yang dinyatakan dalam Persamaan 9.25.

$$\mathbf{R} = \begin{bmatrix} R_{11} & \dots & R_{1m} \\ \vdots & \ddots & \vdots \\ R_{m1} & \dots & R_{mm} \end{bmatrix}; R_{ij} = R(\mathbf{L}, \mathbf{S}_i, \mathbf{S}_j) = \prod_{k=1}^n R_k(l_k, s_{ik}, s_{jk}); i, j = 1, \dots, m \quad (9.25)$$

di mana \mathbf{R} adalah matriks korelasi simetris, yang komponen-komponennya (yaitu, \mathbf{R}_{ij}) adalah koefisien korelasi antara masing-masing dua lokasi desain \mathbf{S}_i dan \mathbf{S}_j . Panjang korelasi optimum untuk setiap komponen k dari masukan di lokasi desain (yaitu, l_k) dapat ditentukan oleh Persamaan 9.26 dengan mempertimbangkan proses stokastik sebagai proses Gaussian.

$$L^* = \min_L \left\{ |\mathbf{R}|^{\frac{1}{m}} \sigma_k^2 \right\}; k = 1, \dots, n \quad (9.26)$$

di mana L^* adalah vektor panjang korelasi yang dioptimalkan dan σ_k adalah deviasi standar komponen k dalam respons (dari q respons), L adalah vektor panjang korelasi, dan $|\mathbf{R}|$ adalah determinan matriks korelasi \mathbf{R} . Penentuan σ_k dijelaskan nanti dalam bab ini.

Dari fungsi korelasi dan deviasi standar, kovariansi antara setiap dua lokasi desain dapat dinyatakan sebagai perkalian koefisien korelasinya dengan varians (dengan mempertimbangkan varians konstan untuk keseluruhan proses). Kovariansi ini juga merupakan nilai harapan dari produk proses acak yang dievaluasi di kedua lokasi ini. Persamaan 9.27 dan 9.28 masing-masing menunjukkan korelasi antara dua lokasi desain yang berbeda dan lokasi desain dengan lokasi yang responsnya diinginkan.

$$COV(\mathbf{L}, \mathbf{S}_i, \mathbf{S}_j) = E(z_k(\mathbf{S}_i)z_k(\mathbf{S}_j)) = \sigma^2 R(\mathbf{L}, \mathbf{S}_i, \mathbf{S}_j); i, j = 1, \dots, m \quad (9.27)$$

$$COV(\mathbf{L}, \mathbf{X}, \mathbf{S}_i) = E(z_k(\mathbf{X})z_k(\mathbf{S}_i)) = \sigma^2 R(\mathbf{L}, \mathbf{X}, \mathbf{S}_i); i = 1, \dots, m \quad (9.28)$$

di mana COV adalah fungsi kovariansi, dan $E(T)$ adalah nilai harapan argumen T . Matriks korelasi \mathbf{R} dan \mathbf{r} terkait dengan matriks kovariansi \mathbf{V} dan \mathbf{v} , yang juga dapat ditemukan dengan

memperluas Persamaan 9.27 dan 9.28 untuk membentuk format matriks, seperti yang diungkapkan dalam Persamaan 9.29 dan 9.30.


$$V = \begin{bmatrix} E(z_k(\mathcal{S}_1), z_k(\mathcal{S}_1)) & \cdots & E(z_k(\mathcal{S}_1), z_k(\mathcal{S}_m)) \\ \vdots & \ddots & \vdots \\ E(z_k(\mathcal{S}_m), z_k(\mathcal{S}_1)) & \cdots & E(z_k(\mathcal{S}_m), z_k(\mathcal{S}_m)) \end{bmatrix} = \sigma^2 \mathbf{R}; k = 1, \dots, q \quad (9.29)$$

$$v = \begin{bmatrix} E(z_k(\mathbf{X}), z_k(\mathcal{S}_1)) \\ \vdots \\ E(z_k(\mathbf{X}), z_k(\mathcal{S}_m)) \end{bmatrix} = \sigma^2 \mathbf{r}; k = 1, \dots, q \quad (9.30)$$


Fungsi korelasi dan kovarians yang merepresentasikan proses stokastik dan fungsi regresi telah dijelaskan sejauh ini. Prediktor yang menggabungkan keduanya adalah prediktor Kriging, di mana nilai rata-rata prediktor ditentukan melalui fungsi regresi, dan varians respons ditentukan oleh proses stokastik seperti yang disajikan pada Gambar 9.5.

Untuk regresi, prediktor mungkin atau mungkin tidak melewati respons di lokasi desain, tetapi untuk Kriging, nilai rata-rata selalu melewati respons yang sesuai dengan lokasi desain, karena adanya proses stokastik. Perlu disebutkan bahwa jenis fungsi regresi dapat mengubah prediktor, karena proses stokastik cenderung beresilasi di sekitar fungsi regresi. Prediktor memberikan nilai rata-rata respons. Selain respons tertentu yang sesuai dengan lokasi desain, semua reaksi yang sesuai dengan lokasi yang diinginkan (respons yang tidak diketahui) bersifat acak, yang berarti diperlakukan sebagai variabel acak dengan varians bukan nol. Dengan kata lain, respons terhadap lokasi desain adalah variabel acak yang memiliki nilai tertentu, tetapi respons terhadap lokasi desain yang diinginkan tidak pasti, seperti yang ditunjukkan pada Gambar 9.6.

Oleh karena itu, terdapat ketidakpastian dalam prediksi lokasi desain yang dapat ditunjukkan oleh selisih deviasi standar pada Gambar 9.6(a), dan oleh distribusi dengan batas atas dan bawah yang sesuai dengan interval kepercayaan yang tepat pada Gambar 9.6(b). Varians adalah ukuran kebaikan kurva, yang berarti prediktor dapat ditingkatkan dengan mengurangi varians prediktor. Oleh karena itu, ide di balik pencarian koefisien yang tidak diketahui dalam prediktor Kriging adalah meminimalkan varians Kriging.



Gambar 9.5 Prediktor Kriging: (a) regresi konstan dan proses stokastik; (a) regresi linier dan proses stokastik; (a) regresi kuadrat dan proses stokastik.



Gambar 9.6 Varians pada lokasi desain: (a) respons dan variansnya; (b) distribusi respons.

Untuk menemukan koefisien yang tidak diketahui dalam prediktor Kriging, varians diperlukan, dan untuk membangun varians, estimasi respons riil diperlukan. Pertimbangkan perhitungan respons untuk sistem dengan hanya satu reaksi. Evaluasi prediktor Kriging (yaitu, Persamaan 9.7) pada setiap lokasi desain S_i dapat ditunjukkan pada Persamaan 9.31, dan ekspansinya untuk semua lokasi desain dapat diperluas pada Persamaan 9.32.

$$y_{i1} = \beta_{11}f_1(\mathbf{S}_i) + \dots + \beta_{p1}f_p(\mathbf{S}_i) + z_1(\mathbf{S}_i) \tag{9.31}$$

$$\mathbf{Y} = \mathbf{Y}_1 = \begin{bmatrix} y_{11} \\ \vdots \\ y_{m1} \end{bmatrix} = \begin{bmatrix} F_{11} & \dots & F_{1p} \\ \vdots & \ddots & \vdots \\ F_{m1} & \dots & F_{mp} \end{bmatrix} \begin{bmatrix} \beta_{11} \\ \vdots \\ \beta_{p1} \end{bmatrix} + \begin{bmatrix} z_1(\mathbf{S}_1) \\ \vdots \\ z_1(\mathbf{S}_m) \end{bmatrix} = \mathbf{F}\boldsymbol{\beta} + \mathbf{Z} \tag{9.32}$$

di mana \mathbf{Y} adalah matriks respons yang diketahui untuk lokasi desain, \mathbf{Y}_1 adalah vektor respons untuk himpunan respons pertama (dari q), y_{ij} adalah respons untuk lokasi desain \mathbf{S}_i yang diketahui, dan himpunan respons j (dari q), dan \mathbf{Z} adalah vektor proses stokastik untuk lokasi desain.

Asumsikan bahwa respons yang diestimasi ($\bar{y}(\mathbf{X})$) untuk lokasi \mathbf{X} tertentu dengan respons yang tidak diketahui yang diinginkan merupakan kombinasi linear dari respons untuk semua lokasi desain, yang disajikan dalam Persamaan 9.33.

$$\bar{y}(\mathbf{X}) = \mathbf{c}(\mathbf{X})^T \mathbf{Y} = [c_1(\mathbf{X}) \dots c_m(\mathbf{X})] \begin{bmatrix} y_{11} \\ \vdots \\ y_{m1} \end{bmatrix} = \mathbf{c}^T (\mathbf{F}\boldsymbol{\beta} + \mathbf{Z}) \tag{9.33}$$

di mana ($\bar{y}(\mathbf{X})$) adalah respons yang diestimasi terhadap \mathbf{X} , $\mathbf{c}(\mathbf{X})$ adalah vektor bobot $c_i(\mathbf{X})$ untuk respons y_{i1} . Untuk membangun varians, estimasi respons juga diperlukan. Untuk

prediktor Kriging dengan hanya satu respons, respons terhadap \mathbf{X} disajikan dalam Persamaan 9.34.

$$\hat{y}(\mathbf{X}) = \hat{y}_1(\mathbf{X}) = [f_1(\mathbf{X}) \dots f_p(\mathbf{X})] \begin{bmatrix} \beta_{11} \\ \vdots \\ \beta_{p1} \end{bmatrix} + z_1(\mathbf{X}) = f(\mathbf{X})^T \boldsymbol{\beta} + z \quad (9.34)$$

di mana $\hat{y}(\mathbf{X})$ adalah respons yang diestimasi untuk lokasi \mathbf{X} menggunakan persamaan Kriging (yaitu, Persamaan 9.10).

Untuk mendapatkan estimator yang tidak bias, diperlukan rata-rata galat nol, dan pengurangan varians diperlukan untuk mendapatkan estimator terbaik. Persamaan 9.35 menunjukkan nilai ekspektasi galat, dan dengan mensubstitusikan Persamaan 9.33 dan 9.34 ke dalam Persamaan 9.35 dan menyederhanakan hasilnya, galat ekspektasi atau rata-rata galat dapat ditunjukkan pada Persamaan 9.36.

$$\mu_e = E[e] = E[(\bar{y}(\mathbf{X}) - \hat{y}(\mathbf{X}))] \quad (9.35)$$

$$\begin{aligned} E[(\bar{y}(\mathbf{X}) - \hat{y}(\mathbf{X}))] &= E[(\mathbf{c}^T (\mathbf{F}\boldsymbol{\beta} + \mathbf{Z}) - (f(\mathbf{X})^T \boldsymbol{\beta} + \mathbf{z}))] \\ &= E[(\mathbf{c}^T \mathbf{Z} - \mathbf{z} + (\mathbf{F}^T \mathbf{c} - f(\mathbf{X}))^T \boldsymbol{\beta})] \\ &= E[\mathbf{c}^T \mathbf{Z}] - E[\mathbf{z}] + E[(\mathbf{F}^T \mathbf{c} - f(\mathbf{X}))^T \boldsymbol{\beta}] \end{aligned} \quad (9.36)$$

di mana μ_e adalah rata-rata galat dan e adalah galat.

Untuk memenuhi kondisi tak bias bagi prediktor, nilai ekspektasi galat harus ditetapkan menjadi nol. Dengan demikian, Persamaan 9.36 seharusnya nol. Nilai ekspektasi \mathbf{Z} dan \mathbf{z} adalah nol karena rata-rata proses stokastik $z_i(\mathbf{X})$ diasumsikan nol untuk prediktor Kriging. Oleh karena itu, hanya suku ketiga dari kalimat terakhir dalam Persamaan 9.36 yang seharusnya nol untuk memenuhi kondisi tak bias, seperti yang disajikan dalam Persamaan 9.37.

$$E[(\bar{y}(\mathbf{X}) - \hat{y}(\mathbf{X}))] = E[(\mathbf{F}^T \mathbf{c} - f(\mathbf{X}))^T \boldsymbol{\beta}] = 0 \rightarrow (\mathbf{F}^T \mathbf{c} - f(\mathbf{X}))^T \boldsymbol{\beta} = \mathbf{0} \quad (9.37)$$

Karena matriks koefisien regresi $\boldsymbol{\beta}$ tidak boleh sama dengan nol (jawaban yang mudah), maka Persamaan 9.37 mengarah ke Persamaan 9.38 dan 9.39 sebagai kondisi yang tidak bias dan prediksi kesalahan yang disederhanakan, masing-masing.

$$\mathbf{F}^T \mathbf{c} = f(\mathbf{X}) \quad (9.38)$$

$$e = \bar{y}(\mathbf{X}) - \hat{y}(\mathbf{X}) = \mathbf{c}^T \mathbf{Z} - \mathbf{z} \quad (9.39)$$

Kesalahan kuadrat yang diharapkan adalah varians kesalahan, yang juga disebut sebagai kesalahan kuadrat rata-rata, seperti yang disajikan dalam Persamaan 9.40.

$$\phi(\mathbf{X}) = \sigma_e^2 = \text{Var}(e) = E[(e - \mu_e)^2] = E[e^2] = E[(\bar{y}(\mathbf{X}) - \hat{y}(\mathbf{X}))^2] \quad (9.40)$$

di mana σ_e^2 adalah varians galat yang merupakan fungsi dari \mathbf{X} dan dapat disebut $\phi(\mathbf{X})$. Penggunaan prediktor tak bias menghasilkan rata-rata nol untuk galat yang disederhanakan dalam Persamaan 9.40. Dengan mensubstitusikan Persamaan 9.39 ke dalam Persamaan 9.40, varians galat dapat ditulis sebagai Persamaan 9.41 untuk respons k (dari q) dan dapat diperluas untuk membentuk Persamaan 9.42.

$$\begin{aligned} \phi(\mathbf{X}) = \text{Var}(e) = E[(\mathbf{c}^T \mathbf{Z} - z)^2] &= E[z^2 + \mathbf{c}^T \mathbf{Z} \mathbf{Z}^T \mathbf{c} - 2\mathbf{c}^T \mathbf{Z} z] = E[z_k(\mathbf{X})z_k(\mathbf{X})] + \\ \mathbf{c}^T E \begin{bmatrix} z_k(\mathbf{S}_1) \\ \vdots \\ z_k(\mathbf{S}_m) \end{bmatrix} [z_k(\mathbf{S}_1) \cdots z_k(\mathbf{S}_m)]^T \mathbf{c} - 2\mathbf{c}^T E \begin{bmatrix} z_k(\mathbf{S}_1) \\ \vdots \\ z_k(\mathbf{S}_m) \end{bmatrix} z_k(\mathbf{X}) &= \end{aligned} \quad (9.41)$$

$$\begin{aligned} E[z_k(\mathbf{X})z_k(\mathbf{X})] + \mathbf{c}^T \begin{bmatrix} E(z_k(\mathbf{S}_1)z_k(\mathbf{S}_1)) & \cdots & E(z_k(\mathbf{S}_1)z_k(\mathbf{S}_m)) \\ \vdots & \ddots & \vdots \\ E(z_k(\mathbf{S}_m)z_k(\mathbf{S}_1)) & \cdots & E(z_k(\mathbf{S}_m)z_k(\mathbf{S}_m)) \end{bmatrix} \mathbf{c} - \\ 2\mathbf{c}^T \begin{bmatrix} E(z_k(\mathbf{X})z_k(\mathbf{S}_1)) \\ \vdots \\ E(z_k(\mathbf{X})z_k(\mathbf{S}_m)) \end{bmatrix} &= \sigma^2 + \mathbf{c}^T \mathbf{V} \mathbf{c} - 2\mathbf{c}^T \mathbf{v}; k = 1, \dots, q \end{aligned} \quad (9.42)$$

$$\phi(\mathbf{X}) = \text{Var}(e) = \sigma_k^2(1 + \mathbf{c}^T \mathbf{R} \mathbf{c} - 2\mathbf{c}^T \mathbf{r})$$

Sebagaimana dibahas sebelumnya, koefisien Kriging yang tidak diketahui dapat ditemukan dengan meminimalkan prediktor tak bias. Oleh karena itu, minimisasi bersyarat yang ditunjukkan pada Persamaan 9.43 menghasilkan solusi. Dengan menggunakan pendekatan Lagrangian untuk penyelesaiannya, Persamaan 9.44 merumuskan masalah optimasi bersyarat.

$$\mathcal{L}(\mathbf{c}, \boldsymbol{\lambda}) = \sigma_k^2(1 + \mathbf{c}^T \mathbf{R} \mathbf{c} - 2\mathbf{c}^T \mathbf{r}) - \boldsymbol{\lambda}^T (\mathbf{F}^T \mathbf{c} - f(\mathbf{X})) \quad (9.44)$$

dengan $\boldsymbol{\lambda}$ adalah pengali Lagrange tak tentu, \mathcal{L} adalah ekspresi Lagrangian, dan $(\mathbf{c}, \boldsymbol{\lambda})$ adalah titik stasioner (yaitu, titik di mana turunan parsial pertama \mathcal{L} bernilai nol). Dengan menetapkan turunan pertama Persamaan 9.44, Persamaan 9.45 dapat ditulis dan diperluas ke Persamaan 9.46 dan 9.47, serta diringkas dalam Persamaan 9.48.

$$\frac{\partial (\mathcal{L}, \boldsymbol{\lambda})}{\partial \mathbf{c}} = 2\sigma_k^2(\mathbf{R} \mathbf{c} - \mathbf{r}) - \mathbf{F} \boldsymbol{\lambda} = \mathbf{0} \quad (9.45)$$

$$2\sigma_k^2(\mathbf{R}\mathbf{c} - \mathbf{r}) - \mathbf{F}\boldsymbol{\lambda} = \mathbf{0} \rightarrow \mathbf{R}\mathbf{c} - \mathbf{r} - \mathbf{F}\frac{\boldsymbol{\lambda}}{2\sigma_k^2} = \mathbf{0} \rightarrow \mathbf{R}\mathbf{c} + \mathbf{F}\bar{\boldsymbol{\lambda}} = \mathbf{r}; \bar{\boldsymbol{\lambda}} = -\frac{\boldsymbol{\lambda}}{2\sigma_k^2} \quad (9.46)$$

$$\mathbf{R}^{-1}\mathbf{R}\mathbf{c} + \mathbf{R}^{-1}\mathbf{F}\bar{\boldsymbol{\lambda}} = \mathbf{R}^{-1}\mathbf{r} \rightarrow \mathbf{c} + \mathbf{R}^{-1}\mathbf{F}\bar{\boldsymbol{\lambda}} = \mathbf{R}^{-1}\mathbf{r} \rightarrow \mathbf{c} = \mathbf{R}^{-1}\mathbf{r} - \mathbf{R}^{-1}\mathbf{F}\bar{\boldsymbol{\lambda}} \rightarrow \mathbf{c} = \mathbf{R}^{-1}(\mathbf{r} - \mathbf{F}\bar{\boldsymbol{\lambda}}) \quad (9.47)$$

$$\mathbf{c} = \mathbf{R}^{-1}(\mathbf{r} - \mathbf{F}\bar{\boldsymbol{\lambda}}); \bar{\boldsymbol{\lambda}} = -\frac{\boldsymbol{\lambda}}{2\sigma_k^2} \quad (9.48)$$

Dengan mensubstitusikan nilai \mathbf{c} dari Persamaan 9.48 ke Persamaan 9.38 yang merupakan kondisi tak bias, Persamaan 9.49, dan versi ringkasannya Persamaan 9.50, menentukan nilai $\bar{\boldsymbol{\lambda}}$ dalam hal parameter prediktor Kriging.

$$\mathbf{F}^T\mathbf{c} = f(\mathbf{X}) \rightarrow \mathbf{F}^T(\mathbf{R}^{-1}(\mathbf{r} - \mathbf{F}\bar{\boldsymbol{\lambda}})) = f(\mathbf{X}) \rightarrow \mathbf{F}^T\mathbf{R}^{-1}\mathbf{r} - \mathbf{F}^T\mathbf{R}^{-1}\mathbf{F}\bar{\boldsymbol{\lambda}} = f(\mathbf{X}) \rightarrow (\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F})^{-1}(\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F})\bar{\boldsymbol{\lambda}} = (\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F})^{-1}(\mathbf{F}^T\mathbf{R}^{-1}\mathbf{r} - f(\mathbf{X})) \quad (9.49)$$

$$\bar{\boldsymbol{\lambda}} = (\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F})^{-1}(\mathbf{F}^T\mathbf{R}^{-1}\mathbf{r} - f(\mathbf{X})) \quad (9.50)$$

Dengan mensubstitusikan nilai $\bar{\boldsymbol{\lambda}}$ dari Persamaan 9.50 dan \mathbf{c} dari Persamaan 9.48 ke dalam estimator $\bar{y}(\mathbf{X})$ dari Persamaan 9.33, maka estimator tersebut dapat disajikan sebagai Persamaan 9.51.

$$\begin{aligned} \bar{y}(\mathbf{X}) &= \mathbf{c}(\mathbf{X})^T \mathbf{Y} = (\mathbf{R}^{-1}(\mathbf{r} - \mathbf{F}\bar{\boldsymbol{\lambda}}))^T \mathbf{Y} \\ &= (\mathbf{r} - \mathbf{F}(\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F})^{-1}(\mathbf{F}^T\mathbf{R}^{-1}\mathbf{r} - f(\mathbf{X})))^T \mathbf{R}^{-1}\mathbf{Y} \\ &= \mathbf{r}^T \mathbf{R}^{-1}\mathbf{Y} - (\mathbf{F}^T\mathbf{R}^{-1}\mathbf{r} - f(\mathbf{X}))^T (\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F})^{-1} \mathbf{F}^T \mathbf{R}^{-1}\mathbf{Y} \end{aligned} \quad (9.51)$$

Perlu dicatat bahwa \mathbf{R} adalah matriks simetris, sehingga \mathbf{R}^{-1} juga simetris. Selain itu, karena $\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F}$ simetris, $(\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F})^{-1}$ juga simetris. Oleh karena itu, \mathbf{R}^{-1T} digantikan oleh \mathbf{R}^{-1} dan $(\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F})^{-1T}$ digantikan oleh $(\mathbf{F}^T\mathbf{R}^{-1}\mathbf{F})^{-1}$ pada Persamaan 9.51. Dengan memasukkan parameter baru $\boldsymbol{\beta}^*$ pada Persamaan 9.52 dan menulis ulang Persamaan 9.51 dalam bentuk $\boldsymbol{\beta}^*$, estimator dapat ditulis dalam bentuk Persamaan 9.53. Dengan mendefinisikan parameter baru $\boldsymbol{\gamma}^*$ dalam Persamaan 9.54, Persamaan 9.53 dapat ditulis dalam bentuk Persamaan 9.55 yang merupakan prediktor Kriging pada bentuk akhirnya.

$$\boldsymbol{\gamma}^* = \mathbf{R}^{-1}(\mathbf{Y} - \mathbf{F}\boldsymbol{\beta}^*) \quad (9.54)$$

$$\bar{y}(\mathbf{X}) = f(\mathbf{X})^T \boldsymbol{\beta}^* + \mathbf{r}(\mathbf{X})^T \boldsymbol{\gamma}^* \quad (9.55)$$

Dengan mencermati Persamaan 9.55, 9.54, dan 9.52, prediktor Kriging berkaitan dengan lokasi desain dan responsnya melalui $\boldsymbol{\beta}^*$ dan $\boldsymbol{\gamma}^*$, dan berkaitan dengan lokasi yang diinginkan hanya melalui $f(\mathbf{X})^T$ dan $\mathbf{r}(\mathbf{X})^T$, yang masing-masing mewakili evaluasi regresi dan proses stokastik.

MSE yang memenuhi kondisi optimasi tak bias (Persamaan 9.43) untuk prediktor Kriging dapat ditentukan. Dengan mensubstitusikan c dari Persamaan 9.48 ke Persamaan 9.42, kondisi prediktor yang dioptimalkan diterapkan, dan Persamaan 9.56 dapat diturunkan.

$$\begin{aligned}
 \varphi_k(X) &= \sigma_k^2(1 + c^T R c - 2c^T r) \\
 &= \sigma_k^2(1 + c^T (R c - 2r)) \\
 &= \sigma_k^2 \left(1 + (R^{-1}(r - F \bar{\lambda}))^T (R R^{-1}(r - F \bar{\lambda}) - 2r) \right) \\
 &= \sigma_k^2 \left(1 + (F \bar{\lambda} - r)^T R^{-1}(r + F \bar{\lambda}) \right) \\
 &= \sigma_k^2 \left(1 + (\bar{\lambda}^T F^T - r^T) R^{-1}(r + F \bar{\lambda}) \right) \\
 &= \sigma_k^2 \left(1 + \bar{\lambda}^T F^T R^{-1} r + \bar{\lambda}^T F^T R^{-1} F \bar{\lambda} - r^T R^{-1} r - r^T R^{-1} F \bar{\lambda} \right)
 \end{aligned} \tag{9.56}$$

di mana $\bar{\lambda}^T F^T R^{-1} r$ adalah matriks 1-kali-1 (yaitu, dengan pemeriksaan dimensi $(1 \times p) \times (p \times m) \times (m \times m) \times (m \times 1)$, hasilnya adalah matriks 1×1), dan ditetapkan sama dengan transposnya $r^T (R^{-1}) F \bar{\lambda}$.

Karena R simetris, R^{-1} adalah matriks simetris, dan transposnya dapat digantikan oleh dirinya sendiri sehingga $r^T (R^{-1})^T F \bar{\lambda}$ dapat digantikan oleh $r^T R^{-1} F \bar{\lambda}$ dan Persamaan 9.56 dapat ditulis sebagai Persamaan 9.57.

$$\varphi_k(X) = \sigma_k^2(1 + \bar{\lambda}^T F^T R^{-1} F \bar{\lambda} - r^T R^{-1} r) \tag{9.57}$$

Dengan menerapkan kondisi tak bias dan mensubstitusikan $\bar{\lambda}$ dari Persamaan 11.50 ke Persamaan 9.57, Persamaan 9.58 dan 9.59 dapat ditentukan.

$$\begin{aligned}
 \varphi_k(X) &= \sigma_k^2 \left(1 + ((F^T R^{-1} F)^{-1} (F^T R^{-1} r - f))^T F^T R^{-1} F (F^T R^{-1} F)^{-1} (F^T R^{-1} r - f) - r^T R^{-1} r \right) \\
 &= \sigma_k^2 \left(1 + (F^T R^{-1} r - f)^T ((F^T R^{-1} F)^{-1})^T F^T R^{-1} F (F^{-1} R F^T)^{-1} (F^T R^{-1} r - f) - r^T R^{-1} r \right) \\
 &= \sigma_k^2 \left(1 + (r^T R^{-1} F - f^T) (F^{-1} R F^T)^{-1} F^T R^{-1} F (F^{-1} R F^T)^{-1} (F^T R^{-1} r - f) - r^T R^{-1} r \right) \\
 &= \sigma_k^2 \left(1 + (r^T R^{-1} F - f^T) (F^{-1} R) R^{-1} (R F^T)^{-1} (F^T R^{-1} r - f) - r^T R^{-1} r \right) \\
 &= \sigma_k^2 \left(1 + (r^T R^{-1} F - f^T) (F^{-1} R F^T)^{-1} (F^T R^{-1} r - f) - r^T R^{-1} r \right) \\
 &= \sigma_k^2 \left(1 + (F^T R^{-1} r - f)^T (F^T R^{-1} F)^{-1} (F^T R^{-1} r - f) - r^T R^{-1} r \right)
 \end{aligned} \tag{9.58}$$

$$\varphi_k(X) = \sigma_k^2 \left(1 + u^T (F^T R^{-1} F)^{-1} u - r^T R^{-1} r \right); \quad u = F^T R^{-1} r - f \tag{9.59}$$

di mana k adalah indeks yang menunjukkan setiap respons (dari q respons).

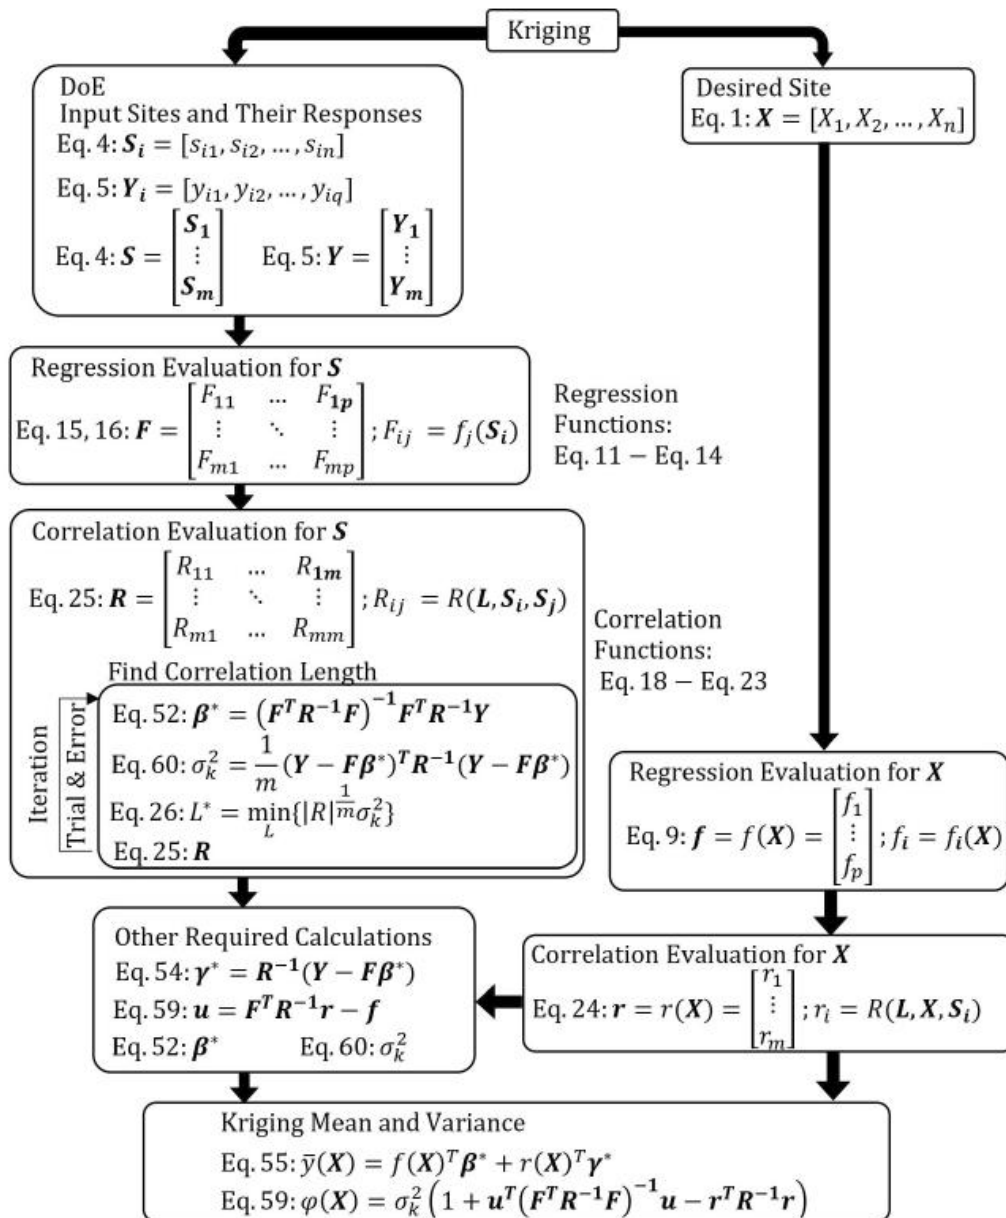
MSE atau varians galat dapat menghasilkan nilai negatif karena tanda negatif f pada Persamaan 9.59. Oleh karena itu, untuk penggunaan persamaan ini lebih lanjut dalam analisis, persamaan ini harus diperlakukan dengan hati-hati untuk menghindari istilah imajiner untuk deviasi standar galat dalam perhitungan selanjutnya. Untuk menemukan nilai σ_k , pendekatan kecocokan kuadrat terkecil tergeneralisasi dapat diterapkan untuk membentuk Persamaan 9.60.

$$\sigma_k^2 = \frac{1}{m} (Y - F\beta^*)^T R^{-1} (Y - F\beta^*) \quad (9.60)$$

Ringkasan eksekutif perhitungan Kriging disajikan dalam Gambar 9.7, di mana Kriging digunakan untuk menemukan respons dari setiap situs yang diinginkan (X) dengan memulai dengan membangun DoE, di mana serangkaian situs input (S_i) dengan respons yang sesuai (Y_i) telah ditentukan sebelumnya menggunakan model asli. Fungsi regresi dapat dipilih dan realisasi regresi yang sesuai untuk situs desain (F) dapat dibangun. Fungsi korelasi dapat dipilih, dan vektor panjang korelasi (L) dapat diasumsikan untuk melanjutkan dengan membangun matriks korelasi situs desain (R).

Kemudian, proses iteratif atau pendekatan coba-coba dapat digunakan untuk menemukan panjang korelasi optimal (L^*) dengan membangun β^* dan σ_k^2 yang sesuai dari Persamaan 9.52 dan 9.60, masing-masing, dan menemukan $|R|^{-\frac{1}{m}} \sigma_k^2$ untuk rentang vektor panjang korelasi (L) untuk menemukan yang memenuhi Persamaan 9.26. L diperlukan untuk membangun R , dan R diperlukan untuk membangun β^* dan σ_k^2 , yang dengannya $|R|^{-\frac{1}{m}} \sigma_k^2$ dapat dibangun. Setelah panjang korelasi optimum ditemukan, sisa parameter yang diperlukan seperti γ^* , u , r , dan f dapat dibangun, yang dengannya mean dan varians Kriging ditentukan, seperti yang disajikan pada Gambar 9.7. Untuk perhitungan, kotak peralatan DACE untuk MATLAB® dapat digunakan, yang menggunakan teknik perhitungan aljabar tingkat lanjut.

Untuk algoritma analisis reliabilitas, seperti metode reliabilitas orde pertama (FORM) atau metode lain yang terkait dengan pencarian gradien lokal, gradien respons dan kesalahan diperlukan, yang dapat ditemukan di Lampiran 9A.1. Karena cakupan bab ini terbatas pada MCS, hanya simulasi Active Learning Kriging Monte Carlo (AK-MCS) yang akan dibahas di bagian berikut.



Gambar 9.7: Ringkasan Kriging.

9.4 SIMULASI MONTE CARLO KRIGING PEMBELAJARAN AKTIF (AK-MCS)

Keandalan struktur rekayasa dapat ditentukan menggunakan prediktor Kriging sebagai pengganti model asli, dan dengan menggabungkannya dengan pilihan metode keandalan. Untuk permasalahan rekayasa kompleks yang memerlukan perhitungan numerik yang berat seperti analisis FE atau FD, evaluasi fungsi kinerja membutuhkan biaya yang mahal dan harus diminimalkan untuk mencapai analisis keandalan yang optimal. Simulasi Monte Carlo (MCS) merupakan metode yang paling akurat jika jumlah percobaan yang dibutuhkan dipertimbangkan. Oleh karena itu, dengan keuntungan memiliki model pengganti yang hemat biaya, MCS dipilih untuk dipelajari dikombinasikan dengan Kriging.

Terdapat metode keandalan berbasis gradien seperti metode keandalan momen kedua orde pertama (FOSM), FORM, metode keandalan orde kedua (SORM), atau teknik reduksi varians seperti pengambilan sampel penting (IS) atau pengambilan sampel garis (LS) yang

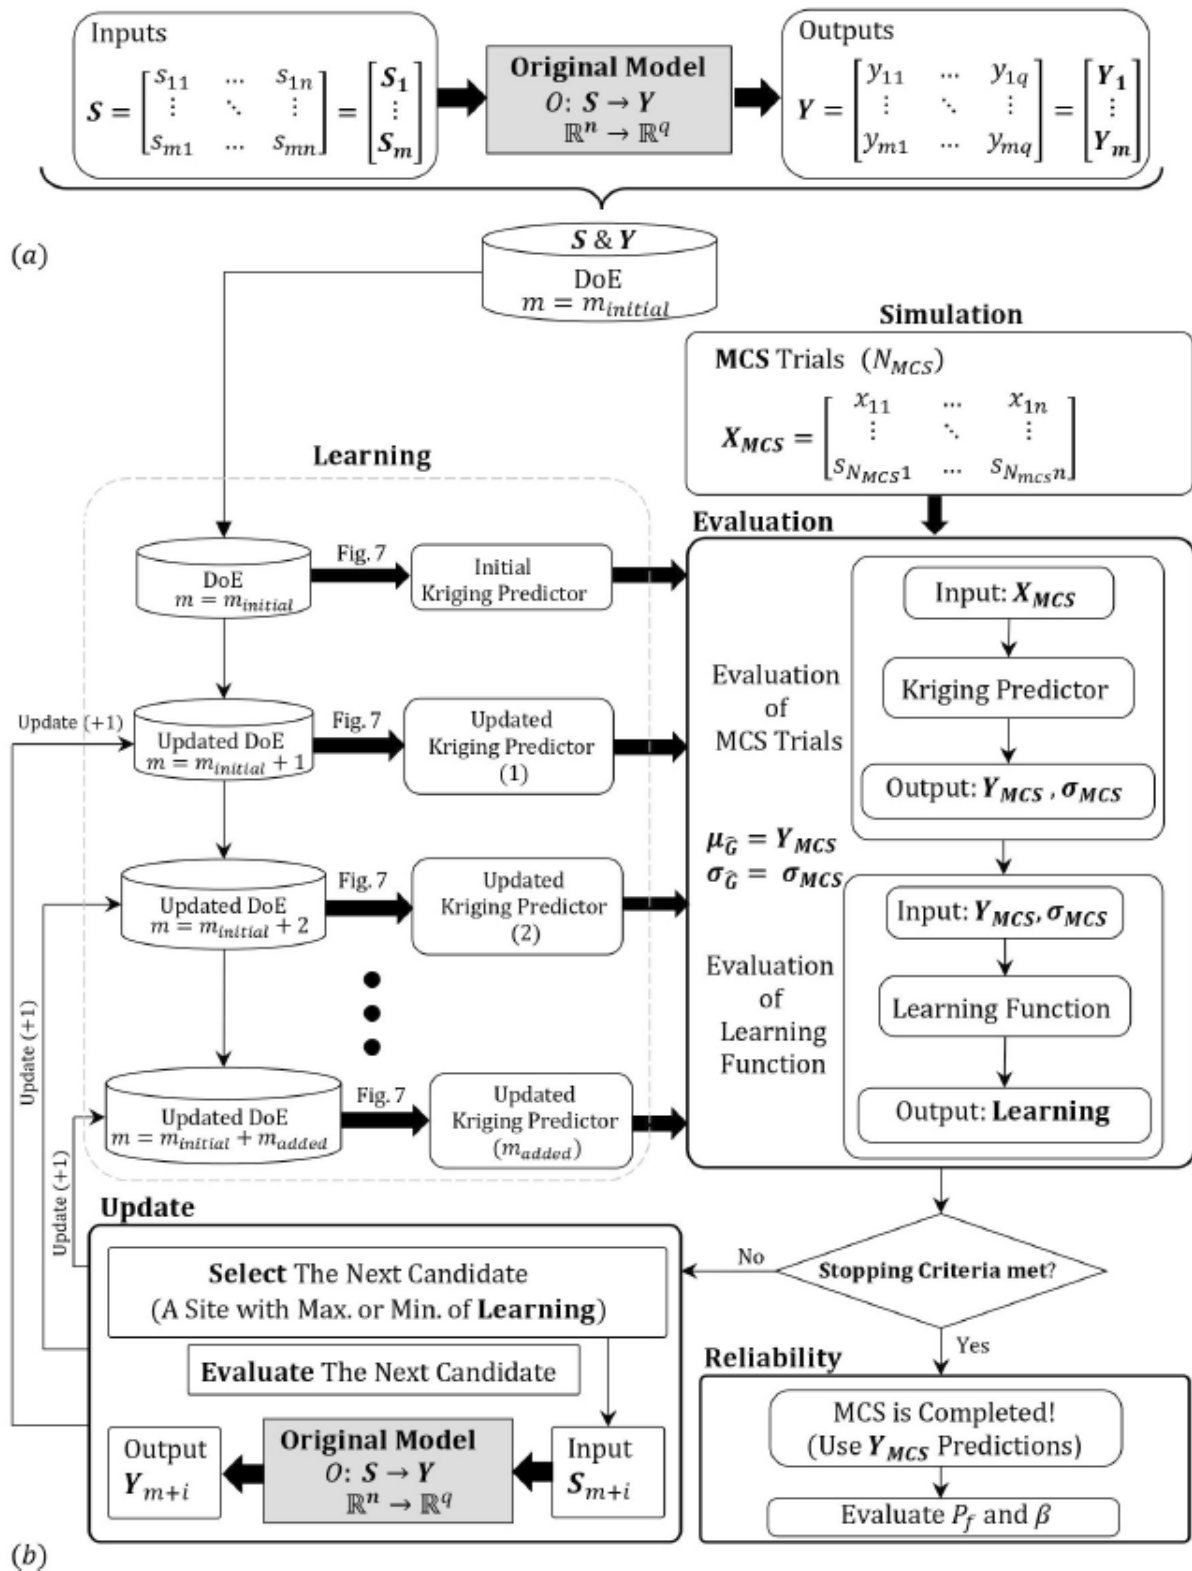
dapat dibandingkan dengan kombinasi Kriging dan metode keandalan. Untuk metode reliabilitas berbasis gradien, pencarian algoritmik diperlukan untuk menemukan titik paling mungkin (MPP) atau titik desain untuk fungsi kinerja dan membangun fungsi aproksimasi orde pertama (untuk FORM) atau orde kedua (untuk SORM) terhadap fungsi kinerja pada MPP.

Dalam analisis reliabilitas, MPP didefinisikan sebagai titik dalam ruang normal baku dengan jarak terpendek dari titik asal. Metode berbasis gradien efisien dibandingkan dengan MCS, tetapi mungkin mengalami ketidakakuratan untuk fungsi kinerja yang sangat nonlinier atau masalah multimoda. Pencarian algoritmik untuk metode berbasis gradien mungkin gagal konvergen untuk gradien bertahap yang tidak dihaluskan untuk masalah yang sangat nonlinier atau mungkin konvergen ke solusi yang buruk untuk masalah dengan beberapa minimum lokal. Untuk teknik reduksi varians, pencarian berbasis gradien harus dilakukan untuk menemukan MPP terlebih dahulu, diikuti oleh MCS tentang MPP, yang menyiratkan bahwa ketidakakuratan yang sama akan terjadi saat menggunakan teknik ini. MCS, metode berbasis gradien, dan teknik reduksi varians dapat digunakan dengan prediktor Kriging, yang memiliki gradien halus dan biaya kalkulasi yang rendah.

Namun, untuk membangun prediktor Kriging yang andal untuk analisis, prediktor tersebut harus dilatih dengan lokasi desain yang cukup di ruang desain. Jumlah lokasi yang dibutuhkan bergantung pada tingkat nonlinieritas dan jumlah variabel acak untuk fungsi kinerja. Tantangan dalam menggabungkan Kriging dan metode lain adalah prediktor Kriging harus memiliki tingkat akurasi yang baik untuk seluruh domain argumen inputnya. Meskipun biaya pelatihan untuk Kriging lebih rendah daripada biaya kalkulasi MCS, pelatihan dapat menjadi mahal untuk masalah keandalan rekayasa praktis yang dianalisis menggunakan perangkat komputer standar.

Oleh karena itu, untuk menghindari biaya pelatihan, metode Kriging dapat dioptimalkan lebih lanjut agar memiliki akurasi yang cukup di sekitar nilai tertentu untuk fungsi kinerja, alih-alih seluruh domain. Hal ini dapat dicapai dengan teknik pembelajaran aktif yang memberikan akurasi yang cukup untuk fungsi kinerja di sekitar nilai yang diinginkan. Nilai yang diinginkan ini sesuai dengan permukaan kegagalan atau fungsi kinerja nol untuk analisis keandalan. Optimasi dilakukan dengan meminimalkan jumlah lokasi desain dengan secara aktif memilih kandidat terbaik untuk melatih Kriging guna mencapai akurasi yang diinginkan. Bab ini hanya menyajikan kombinasi MCS dan Kriging teroptimasi yang dilatih dengan teknik pembelajaran aktif. Teknik pembelajaran aktif ini juga disebut simulasi Kriging Monte Carlo pembelajaran aktif atau AK-MCS.

Algoritma untuk melakukan AK-MCS disajikan pada Gambar 9.8. Sebagai permulaan, m lokasi desain dapat dipilih secara acak, dan responsnya dapat ditentukan menggunakan model asli, seperti yang ditunjukkan pada Gambar 9.8(a). Rangkaian masukan dan keluaran awal ini disebut DoE awal. Pemilihan m lokasi acak ini diadopsi dari studi yang dilakukan oleh Echard dkk. (2011) untuk AK-MCS.



Gambar 9.8 Simulasi Kriging Monte Carlo pembelajaran aktif (AK-MCS): (a) DoE awal; dan (b) prosedur.

Lokasi ini dipilih dengan mempertimbangkan keuntungan memiliki lebih sedikit titik awal yang diperlukan dibandingkan dengan studi sebelumnya oleh Bichon dkk. (2008), yang merekomendasikan Latin Hypercube Sampling (LHS) dengan ukuran $n(n+1)/2$ untuk DoE awal

(yaitu, titik minimum untuk fungsi regresi kuadrat pada Persamaan 9.14, di mana n adalah jumlah variabel acak masukan). Dalam bab ini, DoE awal dipilih hanya berdasarkan m lokasi yang dipilih secara acak dan responsnya (Gambar 9.8(a)), di mana m dapat ditetapkan sebagai nilai apa pun yang lebih besar dari jumlah titik minimum yang diperlukan berdasarkan fungsi regresi yang dipilih (lihat Persamaan 9.14).

Setelah DoE awal dihasilkan, menggunakan algoritma Kriging yang dijelaskan di bagian sebelumnya (lihat Gambar 9.7), prediktor Kriging awal dapat dibangun. Model pengganti dianggap sebagai pengganti fungsi asli pada tahap ini. Dari sisi reliabilitas, banyak lokasi desain input yang dihasilkan secara acak (yaitu, N_{MCS}), yang membentuk matriks input \mathbf{X}_{MCS} dihasilkan. \mathbf{X}_{MCS} kemudian dievaluasi menggunakan prediktor Kriging awal untuk mendapatkan rerata dan deviasi standar dari setiap percobaan MCS.

Perlu ditekankan bahwa dengan menggunakan prediktor Kriging, setiap nilai prediksi adalah variabel acak (Gambar 9.6) yang dicirikan sebagai distribusi normal dengan rerata dan deviasi standarnya ditentukan oleh Kriging (Gambar 9.7), seperti yang dijelaskan sebelumnya. Meskipun nilai rata-rata Kriging dari Persamaan 9,55 dapat digunakan secara langsung, nilai Persamaan 9,59, yang merupakan varians, tidak dapat digunakan secara langsung. Ada kemungkinan varians menjadi negatif menggunakan formulasi Kriging, yang akar kuadratnya imajiner dan harus dihindari. Oleh karena itu, nilai absolut Persamaan 9,59 harus dikuadratkan agar dianggap sebagai simpangan baku.

Matriks untuk rerata dan deviasi baku prediktor masing-masing disebut \mathbf{Y}_{MCS} dan σ_{MCS} , seperti yang disajikan pada Gambar 9.8. Keduanya juga setara dengan rerata (yaitu, $\mu_{\hat{G}}$) dan deviasi baku (yaitu, $\sigma_{\hat{G}}$) dari estimasi fungsi kinerja (yaitu, \hat{G}) untuk setiap percobaan. Rerata dan deviasi baku yang ditemukan oleh prediktor Kriging awal merupakan masukan untuk fungsi pembelajaran yang keluarannya digunakan untuk menentukan tingkat akurasi Kriging awal yang diinginkan. Keluaran fungsi pembelajaran dibandingkan dengan kriteria penghentian untuk fungsi pembelajaran yang dipilih. Kriteria penghentian dapat terdiri dari hanya satu kriteria atau beberapa kondisi.

Jika kriteria penghentian tidak terpenuhi, algoritma dilanjutkan dengan memperbarui DoE awal dengan satu lokasi desain lagi. Situs desain yang sesuai dengan nilai maksimum atau minimum fungsi pembelajaran yang dievaluasi untuk uji coba MCS dipilih sebagai kandidat berikutnya untuk pembaruan. Situs kandidat kemudian dievaluasi oleh model asli (berdasarkan fungsi pembelajaran yang dipilih). Situs desain kandidat dan keluarannya akan memperbarui DoE. Dengan menggunakan DoE yang diperbarui, prediktor Kriging yang diperbarui dapat dibangun, seperti yang ditunjukkan pada Gambar 9.8.

Prediktor yang diperbarui akan digunakan untuk mengevaluasi kembali rerata dan deviasi standar uji coba MCS serta mengevaluasi fungsi pembelajarannya yang sesuai. Kandidat akan dipilih secara berurutan dan selektif, dan DoE akan diperbarui sehingga prediktor Kriging cukup akurat untuk analisis reliabilitas. Setelah prediktor Kriging yang diinginkan dilatih dan kriteria penghentian terpenuhi, analisis reliabilitas dapat dilakukan seperti yang ditunjukkan pada Gambar 9.8. Prediktor Kriging akhir akan digunakan untuk mengevaluasi semua uji coba MCS dan menemukan jumlah uji coba yang gagal (yaitu, n_f).

Probabilitas kegagalan (yaitu, P_f) dapat ditemukan dengan membagi jumlah percobaan yang gagal dengan jumlah total percobaan MCS (yaitu, N_{MCS}) seperti yang disajikan dalam Persamaan 9.61.

$$P_f = \frac{n_f}{N_{MCS}} \quad (9.61)$$

Dengan mempertimbangkan distribusi normal untuk fungsi kinerja, indeks keandalan (yaitu, β) dapat dihitung berdasarkan Persamaan 9.62 atau berdasarkan versi ringkasannya dalam Persamaan 9.63.

$$P_f = P[\text{failure}] = P[\hat{G} < 0] = P\left[\frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}} < -\beta\right] = 1 - \Phi(\beta) \quad (9.62)$$

$$\beta = \Phi^{-1}(1 - P_f) \quad (9.63)$$

di mana Φ dan Φ^{-1} masing-masing adalah fungsi distribusi kumulatif (CDF) dan CDF invers dari distribusi normal baku, sementara parameter lainnya telah didefinisikan sebelumnya.

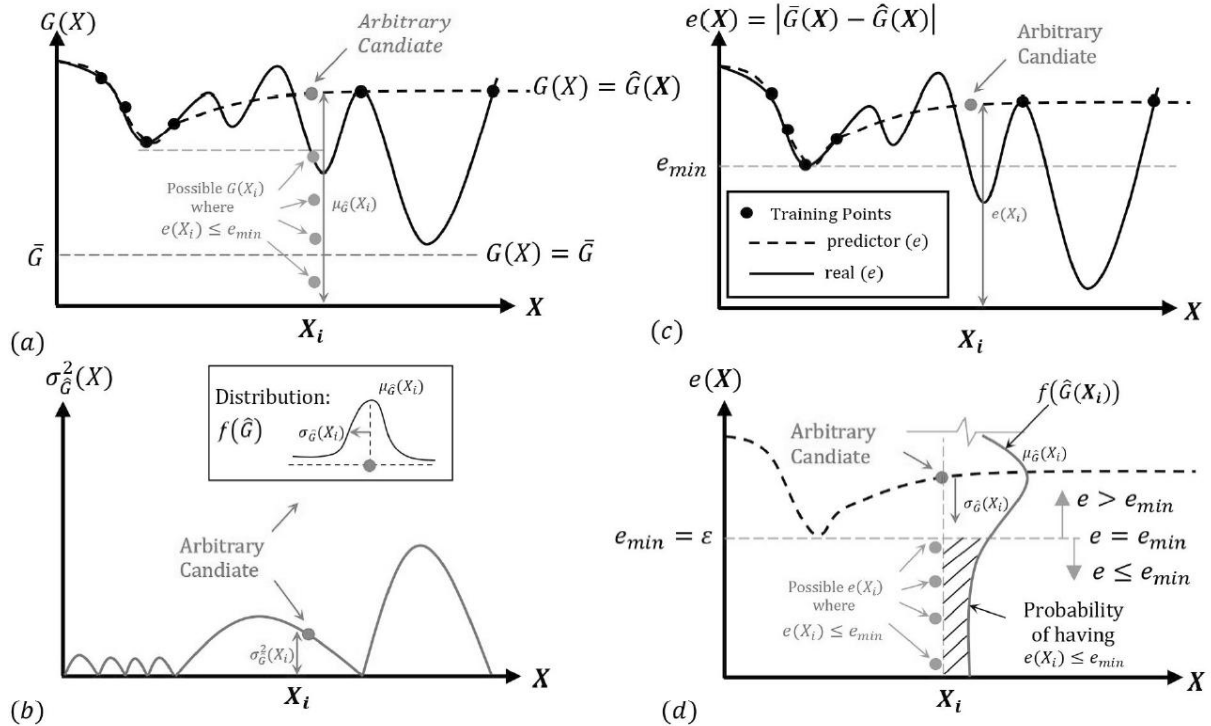
Algoritme yang diilustrasikan pada Gambar 9.8 bersifat umum dan dapat diterapkan pada berbagai fungsi pembelajaran dan kriteria penghentiannya. Banyak fungsi pembelajaran tersedia dalam literatur yang dapat digunakan dengan algoritma yang dijelaskan. Namun, pada bagian berikut, hanya dua fungsi pembelajaran yang umum digunakan yang disajikan secara rinci, yaitu fungsi EFF dan fungsi U.

Fungsi Pembelajaran EFF

Fungsi kelayakan yang diharapkan (EFF) adalah fungsi pembelajaran yang dioptimalkan yang berperan untuk menemukan kandidat terbaik untuk AK-MCS berdasarkan prediktor Kriging saat ini. Konsep fungsi ini berasal dari optimasi global efisien (EGO) yang dikembangkan untuk optimasi global suatu fungsi dengan pengganti proses Gaussian (GP). Bentuk optimasi paling sederhana adalah menggunakan metode permukaan respons (RSM) untuk menyesuaikan suatu permukaan, menemukan nilai minimum permukaan, dan mengambil sampel kandidat terbaik secara iteratif, dengan sampel dipilih mendekati nilai minimum saat ini.

Namun, optimasi RSM dapat dengan mudah konvergen ke minimum lokal dan melewatkan minimum global. RSM tidak memperhitungkan ketidakpastian permukaan respons, sementara EGO mengatasi masalah ini. Dalam EGO, kandidat berikutnya dipilih berdasarkan seberapa besar peningkatan yang diharapkan dalam hasil solusi GP saat ini dapat dicapai. Untuk EGO, kriteria penghentian tercapai ketika peningkatan yang diharapkan dengan menambahkan kandidat berikutnya cukup kecil. Kriteria ini menjawab kebutuhan akan jumlah titik tambahan yang optimal untuk melatih model pengganti. Jika terlalu sedikit sampel yang dipilih, model pengganti akan kurang akurat dan jika terlalu banyak sampel yang dipilih, solusinya akan mahal tanpa perolehan tambahan. Penerapan EGO dalam reliabilitas disebut

analisis reliabilitas global efisien (EGRA) yang memanfaatkan fungsi EFF. Hal ini menghindari terlalu banyak sampel untuk analisis keandalan dengan berfokus pada wilayah di mana fungsi kinerja mendekati nol atau permukaan kegagalan.



Gambar 9.9 Fungsi pembelajaran EFF: (a) Fungsi kinerja; (b) Fungsi MSE (varians kesalahan); (c) fungsi kesalahan absolut; dan (d) penjelasan nilai harapan kesalahan absolut yang lebih rendah dari minimum yang ditentukan.

Derivasi fungsi pembelajaran EFF dikonseptualisasikan dalam Gambar 9.9. Mari kita asumsikan bahwa terdapat sekumpulan titik pelatihan (titik hitam) yang tersedia (diketahui) yang dengannya fungsi pengganti atau prediktor (\hat{G} ditunjukkan dalam garis hitam putus-putus) mengaproksimasi fungsi kinerja riil (garis hitam pekat), seperti yang disajikan pada Gambar 9.9(a). Untuk meningkatkan prediktor, nilai minimum prediktor saat ini ditemukan terlebih dahulu, dan kandidat berikutnya dipilih sehingga pilihan kandidat berikutnya meningkatkan nilai minimum saat ini.

Untuk kandidat arbitrer (X_i ditunjukkan sebagai titik merah), sekumpulan nilai yang mungkin (titik biru) untuk fungsi kinerja riil ditunjukkan pada Gambar 9.9(a). Karena setiap titik yang diprediksi merupakan variabel acak, terdapat probabilitas kemunculan yang terkait dengan setiap nilai yang mungkin (titik biru). Distribusi yang menunjukkan keacakan ini diasumsikan sebagai distribusi normal dengan nilai rata-rata ($\mu_{\hat{G}}(X_i)$) sama dengan prediksi model pengganti pada titik yang dipelajari (X_i), seperti yang ditunjukkan pada Gambar 9.9(a).

Varians distribusi ini ditetapkan sama dengan varians prediktor ($\sigma_{\hat{G}}(X_i)$) pada titik yang dipelajari (X_i), seperti yang ditunjukkan pada Gambar 9.9(b). Memiliki jenis distribusi, rata-rata, dan varians, fungsi kepadatan probabilitas (PDF) dari prediktor (yaitu, $f(\hat{G}(X_i))$) untuk

titik yang dipelajari dapat dibangun, seperti yang ditunjukkan pada Gambar 9.9(b). Dengan karakteristik probabilistik ini untuk prediktor, probabilitas kemunculan setiap kemungkinan hasil atau nilai yang diharapkan dari prediksi di setiap titik dapat dikuantifikasi.

Karena tujuannya bukanlah optimasi global, ekspektasi ini harus dikuantifikasi untuk fungsi galat ($e(X)$) yang merupakan nilai absolut dari selisih antara fungsi kinerja yang diprediksi ($\hat{G}(X)$) dan nilai fungsi kinerja yang diinginkan ($\bar{G}(X)$), seperti yang disajikan pada Gambar 9.9(c). Untuk fungsi galat, galat minimum (yaitu, e_{min}) ditunjukkan pada Gambar 9.9(d). Untuk titik sembarang (titik merah), jika nilai galat (e) lebih besar dari galat minimum saat ini (yaitu, $e > e_{min}$), titik ini bukanlah kandidat yang baik karena tidak dapat memperbaiki galat minimum saat ini. Untuk titik sembarang, jika nilai galat lebih kecil dari galat minimum saat ini (yaitu, $e < e_{min}$), kandidat dapat memperbaiki galat minimum, tetapi belum tentu kandidat tersebut memiliki nilai yang lebih kecil dari minimum saat ini. Oleh karena itu, nilai ekspektasi fungsi galat yang lebih kecil dari minimum saat ini dapat memberikan pengukuran yang baik untuk peluang terjadinya galat di bawah minimum.

Ekspektasi ini divisualisasikan sebagai area yang diarsir di bawah distribusi prediktor (yaitu, $f(\bar{G}(X_i))$) untuk nilai galat yang kurang dari atau sama dengan galat minimum (yaitu, $e \leq e_{min}$) dikalikan dengan semua kemungkinan nilai yang kurang dari minimum, seperti yang ditunjukkan pada Gambar 9.9(d). Fungsi EFF dapat dinyatakan sebagai nilai ekspektasi dari fungsi galat untuk nilai galat yang lebih rendah dari galat minimum seperti yang disajikan pada Persamaan 9.64.

$$EFF(\hat{G}) = E[\max(e_{min} - e, 0)] \quad (9.64)$$

di mana E adalah ekspektasi suatu fungsi, dan \hat{G} adalah format singkat untuk $\hat{G}(X)$, yang merupakan nilai prediksi fungsi kinerja untuk lokasi desain X , dan e dan e_{min} adalah fungsi kesalahan dan kesalahan minimum yang didefinisikan dalam Persamaan 9.65 dan 9.66, masing-masing.

$$e = e(X) = |\hat{G}(X) - \bar{G}(X)| = |\bar{G} - \hat{G}| \quad (9.65)$$

$$e_{min} = \varepsilon \quad (9.66)$$

di mana \bar{G} adalah nilai yang diinginkan dari fungsi kinerja dan sama dengan nol untuk analisis keandalan (juga disebut sebagai keadaan batas), dan ε mendefinisikan tingkat kesalahan yang diperlukan dan biasanya dianggap dua kali simpangan baku pada setiap titik yang diteliti (yaitu, $\varepsilon = 2\sigma_{\hat{G}} \geq 0$), dalam literatur. Dengan mensubstitusikan nilai e dan e_{min} dari Persamaan 9.65 dan Persamaan 9.66 ke dalam Persamaan 9.64, fungsi EFF dapat didefinisikan sebagai Persamaan 9.67.

$$EFF(\hat{G}) = E[\max(\varepsilon - |\bar{G} - \hat{G}|, 0)] \quad (9.67)$$

Untuk menyelesaikan Persamaan 9.67, pertama-tama, argumen nilai maksimum harus dipecah, karena Persamaan 9.68 dan Persamaan 9.69 masing-masing mempertimbangkan dua skenario kesalahan yang lebih besar dari atau sama dengan ε dan kurang dari ε .

$$\begin{aligned} \text{if } \varepsilon - |\bar{G} - \hat{G}| \leq 0 &\rightarrow |\bar{G} - \hat{G}| \geq \varepsilon \rightarrow \bar{G} - \hat{G} \geq \varepsilon \cup \bar{G} - \hat{G} \leq -\varepsilon \\ &\rightarrow \hat{G} \leq \bar{G} - \varepsilon \cup \hat{G} \geq \bar{G} + \varepsilon \rightarrow \hat{G} \leq G^- \cup \hat{G} \geq G^+ \end{aligned} \quad (9.68)$$

$$\begin{aligned} \text{if } \varepsilon - |\bar{G} - \hat{G}| > 0 &\rightarrow |\bar{G} - \hat{G}| < \varepsilon \rightarrow -\varepsilon < \bar{G} - \hat{G} < \varepsilon \\ &\rightarrow \bar{G} - \varepsilon < \hat{G} < \bar{G} + \varepsilon \rightarrow G^- < \hat{G} < G^+ \end{aligned} \quad (9.69)$$

di mana G dan G^+ sama dengan $\bar{G} - \varepsilon$ dan $\bar{G} + \varepsilon$, yang akan digunakan untuk penyederhanaan dalam formulasi. Persamaan 9.68 dan 9.69 dapat digunakan untuk menuliskan nilai maksimum dalam bentuk fungsi sepotong-sepotong seperti yang disajikan pada Persamaan 9.70.

$$\max(\varepsilon - |\bar{G} - \hat{G}|, 0) = \begin{cases} 0 & \text{if } \hat{G} \leq G^- \\ \varepsilon - |\bar{G} - \hat{G}| & \text{if } G^- < \hat{G} < G^+ \\ 0 & \text{if } G^+ \leq \hat{G} \end{cases} \quad (9.70)$$

Fungsi sepotong-sepotong dalam Persamaan 9.70 dapat disubstitusikan ke Persamaan 9.67 dan ekspektasinya dapat diperluas sebagai Persamaan 9.71.

$$\begin{aligned} EFF(\hat{G}) &= E[\max(\varepsilon - |\bar{G} - \hat{G}|, 0)] \\ &= \int_{-\infty}^{\infty} \max(\varepsilon - |\bar{G} - \hat{G}|, 0) f(\hat{G}) d\hat{G} \\ &= \int_{-\infty}^{G^-} (0) f(\hat{G}) d\hat{G} + \int_{G^-}^{G^+} (\varepsilon - |\bar{G} - \hat{G}|) f(\hat{G}) d\hat{G} + \int_{G^+}^{\infty} (0) f(\hat{G}) d\hat{G} \end{aligned} \quad (9.71)$$

Solusi untuk integral ini dapat diikuti dengan membagi Persamaan 9.71 menjadi dua integral terpisah (yaitu, I_1 dan I_2), seperti yang ditunjukkan pada Persamaan 9.72.

$$\begin{aligned} EFF(\hat{G}) &= \int_{G^-}^{G^+} (\varepsilon - |\bar{G} - \hat{G}|) f(\hat{G}) d\hat{G} \\ &= \int_{G^-}^{\bar{G}} (\varepsilon - \bar{G} + \hat{G}) f(\hat{G}) d\hat{G} + \int_{\bar{G}}^{G^+} (\varepsilon - \hat{G} + \bar{G}) f(\hat{G}) d\hat{G} \\ &= \int_{G^-}^{\bar{G}} (\hat{G} - G^-) f(\hat{G}) d\hat{G} + \int_{\bar{G}}^{G^+} (G^+ - \hat{G}) f(\hat{G}) d\hat{G} = I_1 + I_2 \end{aligned} \quad (9.72)$$

Untuk menyelesaikan integral I_1 dan I_2 , PDF prediktor yang merupakan PDF normal dapat diekspansi. Karena solusinya kemudian ditulis dalam distribusi normal baku, PDF dan CDF distribusi normal dan distribusi normal baku disajikan dalam Persamaan 9.73 hingga Persamaan 9.76.

$$\phi(z) = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{z^2}{2}\right\} \quad (9.73)$$

$$\int_{-\infty}^z \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{x^2}{2}\right\} dx = \int_{-\infty}^z \phi(x) dx \rightarrow \int_a^b \phi(x) dx = \Phi(b) - \Phi(a) \quad (9.74)$$

$$f(\hat{G}) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} = \frac{1}{\sigma} \phi\left(\frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \quad (9.75)$$

$$F(\hat{G}) = \int_{-\infty}^{\hat{G}} f(\hat{G}) d\hat{G} = \int_{-\infty}^{\hat{G}} \frac{1}{\sigma} \phi\left(\frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) d\hat{G} \quad (9.76)$$

di mana $\phi(z)$ dan $\Phi(z)$ masing-masing adalah PDF dan CDF dari distribusi normal standar, $f(\hat{G})$ dan $F(\hat{G})$ adalah PDF dan CDF dari distribusi normal untuk prediktor \hat{G} , dan z adalah variabel normal standar yang dapat didefinisikan sebagai Persamaan 9.77.

$$z = \frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}} \quad (9.77)$$

Dengan menggunakan Persamaan 9.73 hingga 9.77, integral I_1 dan I_2 dalam Persamaan 9.72 dapat diselesaikan seperti yang disajikan dalam Persamaan 9.78 dan 9.79, berturut-turut.

$$\begin{aligned} I_1 &= \int_{G^-}^{\bar{G}} (\hat{G} - G^-) f(\hat{G}) d\hat{G} \\ &= \int_{G^-}^{\bar{G}} (\hat{G} - G^- + \mu_{\hat{G}} - \mu_{\hat{G}}) \frac{1}{\sqrt{2\pi}\sigma_{\hat{G}}} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} d\hat{G} \\ &= \frac{\sigma_{\hat{G}}}{\sqrt{2\pi}} \int_{G^-}^{\bar{G}} \frac{(\hat{G} - \mu_{\hat{G}})}{\sigma_{\hat{G}}} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} d\hat{G} \\ &\quad + (\mu_{\hat{G}} - G^-) \int_{G^-}^{\bar{G}} \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} \frac{d\hat{G}}{\sigma_{\hat{G}}} \\ &= -\frac{\sigma_{\hat{G}}}{\sqrt{2\pi}} \int_{G^-}^{\bar{G}} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} d\left(-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right) \\ &\quad + (\mu_{\hat{G}} - G^-) \int_{G^-}^{\bar{G}} \phi\left(\frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) d\left(\frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \\ &= -\sigma_{\hat{G}} \left[\frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} \right]_{G^-}^{\bar{G}} + (\mu_{\hat{G}} - G^-) \left[\Phi\left(\frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right]_{G^-}^{\bar{G}} \\ &= -\sigma_{\hat{G}} \left[\phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \phi\left(\frac{G^- - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right] + (\mu_{\hat{G}} - G^-) \left[\Phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \Phi\left(\frac{G^- - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right] \end{aligned} \quad (9.78)$$

$$\begin{aligned}
 I_2 &= \int_{\bar{G}}^{\sigma^+} (G^+ - \hat{G})f(\hat{G})d\hat{G} \\
 &= \int_{\bar{G}}^{\sigma^+} (G^+ - \hat{G} + \mu_{\hat{G}} - \mu_{\hat{G}}) \frac{1}{\sqrt{2\pi}\sigma_{\hat{G}}} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} d\hat{G} \\
 &= \frac{\sigma_{\hat{G}}}{\sqrt{2\pi}} \int_{\bar{G}}^{\sigma^+} -\frac{(\hat{G} - \mu_{\hat{G}})}{\sigma_{\hat{G}}} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} d\hat{G} \\
 &\quad + (G^+ - \mu_{\hat{G}}) \int_{\bar{G}}^{\sigma^+} \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} \frac{d\hat{G}}{\sigma_{\hat{G}}} \\
 &= \frac{\sigma_{\hat{G}}}{\sqrt{2\pi}} \int_{\bar{G}}^{\sigma^+} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} d\left(-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right) \\
 &\quad + (G^+ - \mu_{\hat{G}}) \int_{\bar{G}}^{\sigma^+} \phi\left(\frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) d\left(\frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \\
 &= \sigma_{\hat{G}} \left[\frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{(\hat{G} - \mu_{\hat{G}})^2}{2\sigma_{\hat{G}}^2}\right\} \right]_{\bar{G}}^{\sigma^+} + (G^+ - \mu_{\hat{G}}) \left[\Phi\left(\frac{\hat{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right]_{\bar{G}}^{\sigma^+} \\
 &= \sigma_{\hat{G}} \left[\phi\left(\frac{G^+ - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right] + (G^+ - \mu_{\hat{G}}) \left[\Phi\left(\frac{G^+ - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \Phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right]
 \end{aligned} \tag{9.79}$$

Dengan mensubstitusikan Persamaan 9.78 dan 9.79 ke dalam Persamaan 9.72, fungsi EFF dapat dituliskan dalam Persamaan 9.80 dan bentuk akhirnya dapat disajikan sebagai Persamaan 9.81.

$$\begin{aligned}
 EFF(\hat{G}) &= I_1 + I_2 \\
 &= -\sigma_{\hat{G}} \left[\phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \phi\left(\frac{G^- - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right] \\
 &\quad + (\mu_{\hat{G}} - \bar{G} + \varepsilon) \left[\Phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \Phi\left(\frac{G^- - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right] \\
 &\quad + \sigma_{\hat{G}} \left[\phi\left(\frac{G^+ - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right] \\
 &\quad + (\bar{G} + \varepsilon - \mu_{\hat{G}}) \left[\Phi\left(\frac{G^+ - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \Phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right]
 \end{aligned} \tag{9.80}$$

$$\begin{aligned}
 EFF(\hat{G}) &= (\mu_{\hat{G}} - \bar{G}) \left[2\Phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \Phi\left(\frac{G^+ - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \Phi\left(\frac{G^- - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right] \\
 &\quad - \sigma_{\hat{G}} \left[2\phi\left(\frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \phi\left(\frac{G^+ - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \phi\left(\frac{G^- - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right] \\
 &\quad + \varepsilon \left[\Phi\left(\frac{G^+ - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) - \Phi\left(\frac{G^- - \mu_{\hat{G}}}{\sigma_{\hat{G}}}\right) \right]
 \end{aligned} \tag{9.81}$$

Untuk AK-MCS, prosedur yang ditunjukkan dalam Gambar 11.8 dapat digunakan dengan fungsi EFF dan kriteria penghentian terpenuhi setelah nilai maksimum untuk fungsi EFF mencapai kelayakan 0,001, seperti yang disajikan dalam Persamaan 9.82.

$$\max \left(EFF(\hat{G}_i) \right) = 0.001; \hat{G}_i = \hat{G}(X_i); i = 1, \dots, N_{MCS} \quad (9.82)$$

di mana \hat{G}_i adalah evaluasi fungsi kinerja pada uji MCS yang sesuai dengan lokasi X_i .

Sebagaimana disebutkan sebelumnya, fungsi pembelajaran dievaluasi pada setiap titik dengan keluaran Kriging yang merupakan rerata ($\mu_{\hat{G}_i}$) dan deviasi baku ($\sigma_{\hat{G}_i}$) dari \hat{G}_i untuk setiap uji MCS. Fungsi pembelajaran kedua yang disajikan di bagian berikut hanya menggunakan kedua nilai ini dan mengkarakterisasi optimasi.

Fungsi Pembelajaran U

Pentingnya tanda fungsi kinerja dalam MCS mendorong diperkenalkannya fungsi pembelajaran yang disebut fungsi pembelajaran U . Tanda fungsi kinerja dapat diubah mendekati fungsi kinerja nol (juga disebut keadaan batas). Fungsi pembelajaran U (yaitu, $U(X)$) didefinisikan sebagai persamaan linear yang menentukan jumlah deviasi standar (yaitu, $\sigma_{\hat{G}}(X)$) antara jarak nilai prediktor (yaitu, $\hat{G}(X)$) dan nilai nol (atau keadaan batas) untuk setiap lokasi desain X , seperti yang disajikan pada Persamaan 9.83.

$$|\hat{G}(X)| - U(X)\sigma_{\hat{G}}(X) = 0 \quad (9.83)$$

di mana $|\hat{G}(X)|$ adalah nilai absolut prediktor.

U dapat dianggap sebagai indeks reliabilitas untuk membuat kesalahan pada tanda fungsi kinerja. Nilai 2 untuk reliabilitas minimum untuk membuat kesalahan pada tanda fungsi kinerja per Persamaan 9.83 ditetapkan sebagai kriteria penghentian untuk fungsi pembelajaran U (yang sama dengan probabilitas $1 - \Phi(2)$ atau 2,275% per Persamaan 9.62). Dari Persamaan 9.83, dengan mengganti $|\hat{G}(X)|$ dengan rata-rata prediktor Kriging, nilai fungsi pembelajaran U dapat ditulis ulang seperti yang disajikan pada Persamaan 9.84.

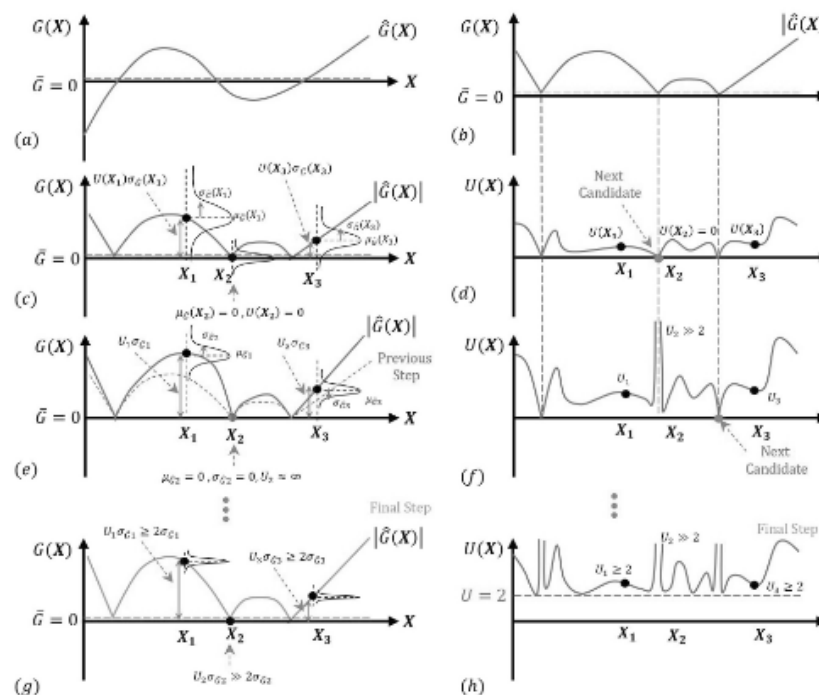
$$U(X) = \frac{\mu_{\hat{G}}(X)}{\sigma_{\hat{G}}(X)} \quad (9.84)$$

Prosedur AK-MCS menggunakan fungsi U leaning disajikan dalam Gambar 9.10. Fungsi kinerja dan nilai absolutnya yang ditentukan oleh prediktor Kriging ditunjukkan dalam Gambar 9.10(a) dan 9.10(b), masing-masing, untuk tahap analisis awal menggunakan DoE awal. Dalam Gambar 9.3(c), distribusi respons di tiga lokasi desain ditunjukkan (yaitu, X_1 , X_2 , dan X_3).

Untuk menemukan kandidat berikutnya di antara ketiganya, kandidat dengan fungsi U terendah (yaitu, X_2) dipilih sebagai kandidat berikutnya untuk memperbarui fungsi Kriging. Nilai fungsi U yang sesuai dengan Gambar 9.10(c) ditunjukkan dalam Gambar 9.10(d). Nilai U untuk X_2 adalah nol yang berarti titik tersebut berada pada keadaan batas dan harus

ditambahkan. Fungsi U untuk X_1 lebih rendah dari X_3 , meskipun nilai rata-rata X_1 lebih besar dari X_3 . Yang terakhir terjadi karena pembentuk distribusi yang lebih tajam pada X_3 (yaitu, simpangan baku yang lebih kecil), yang berarti jarak antara titik dan fungsi kinerja nol ditentukan oleh jumlah simpangan baku yang lebih besar (seperti yang ditunjukkan oleh jarak merah pada Gambar 9.10(c)).

Dengan memperbarui model pengganti dengan X_2 , simpangan baku untuk distribusi semua lokasi input akan berkurang, dan simpangan baku titik yang ditambahkan menjadi nol, karena diperlakukan sebagai titik tertentu, seperti yang ditunjukkan pada Gambar 9.10(e). Perubahan simpangan baku distribusi ini memperbarui fungsi U dan karena simpangan baku menurun pada setiap langkah, nilai fungsi U meningkat dan fungsi U cenderung tak terhingga untuk titik-titik tertentu (yang simpangan bakunya nol), seperti yang ditunjukkan pada Gambar 9.10(f). Setelah lokasi desain yang cukup (yaitu, X_i) ditambahkan untuk memperbarui model pengganti, ketidakpastian dalam distribusi berkurang, dan kriteria penghentian 2 untuk fungsi U akan terpenuhi, seperti yang ditunjukkan pada Gambar 9.10(g) dan 9.10(h).



Gambar. 9.10: Fungsi Pembelajaran U: (a) fungsi kinerja; (b) fungsi kinerja absolut; (c) distribusi respons di awal AK-MCS; (d) fungsi U di awal AK-MCS; (e) prediktor dan distribusi yang diperbarui; (f) fungsi U yang diperbarui; (g) prediktor di langkah akhir dan distribusi; (h) fungsi U di langkah akhir AK-MCS.

Ringkasan eksekutif fungsi pembelajaran yang dibahas disajikan pada Tabel 9.1 untuk tujuan praktis. Algoritma AK-MCS yang dijelaskan pada Gambar 9.8 dan Tabel 9.1 dapat digunakan bersama untuk mengimplementasikan prosedur secara efektif.

Perlu dicatat bahwa bab ini lebih berfokus pada AK-MCS, dengan pembahasan tentang penggunaan metode reliabilitas lain menggunakan prediktor Kriging. Berbagai kombinasi

metode reliabilitas dan Kriging tersedia dalam literatur, termasuk pengambilan sampel penting (IS) berbasis Kriging, pengambilan sampel garis (LS) berbasis Kriging, dan simulasi subset (SS) berbasis Kriging. Lebih lanjut, teknik pembelajaran aktif dapat dikombinasikan dengan jaringan saraf tiruan (JST) dalam bentuk modifikasi bobot, dan pembelajaran penguatan (RL) untuk analisis reliabilitas.

Selain itu, hanya dua fungsi pembelajaran yang dibahas dalam bab ini, sementara lebih banyak fungsi pembelajaran dapat ditemukan dalam literatur. Pada bagian selanjutnya, tiga contoh akan diselesaikan menggunakan AK-MCS. Dalam contoh-contoh ini, kecuali untuk bagian Kriging, algoritmanya dikembangkan dalam MATLAB oleh penulis. Untuk Kriging, digunakan perangkat lunak DACE MATLAB yang telah mapan.

Tabel 9.1 Fungsi pembelajaran.

No.	Fungsi Pembelajaran	Kriteria Pemberhentian	Referensi
1	$EFF(\hat{G}) = (\mu_{\hat{G}} - \bar{G})[2\bar{\Phi} - \Phi^+ - \Phi^-] - \sigma_{\hat{G}}[2\bar{\Phi} - \Phi^+ - \Phi^-] + \varepsilon[\Phi^+ - \Phi^-]$	$\text{Max}(EFF(\hat{G}_i)) \leq 0.001$	(Bichon et al., 2008)
2	$U(\hat{G}) = \frac{ \mu_{\hat{G}} }{\sigma_{\hat{G}}}$	$\text{Min}(U(\hat{G}_i)) \geq 2$	(Echard et al., 2011)

$$\hat{G} = \hat{G}(X); \sigma_{\hat{G}} = \sigma_{\hat{G}}(X); \mu_{\hat{G}} = \mu_{\hat{G}}(X)$$

$$\bar{G} = \bar{G}(X); G^+ = G^+(X) = \bar{G}(X) + \varepsilon; G^- = G^-(X) = \bar{G}(X) - \varepsilon;$$

$$\bar{Z} = \frac{\bar{G} - \mu_{\hat{G}}}{\sigma_{\hat{G}}}; Z^+ = \frac{G^+ - \mu_{\hat{G}}}{\sigma_{\hat{G}}}; Z^- = \frac{G^- - \mu_{\hat{G}}}{\sigma_{\hat{G}}};$$

$$\bar{\Phi} = \Phi(\bar{Z}); \Phi^+ = \Phi(Z^+); \Phi^- = \Phi(Z^-);$$

$$\bar{\phi} = \phi(\bar{Z}); \phi^+ = \phi(Z^+); \phi^- = \phi(Z^-).$$

9.5 PENERAPAN AK-MCS

Contoh 1: Keandalan Balok Beton

Keandalan balok beton persegi panjang dengan lebar 350 mm, tinggi 400 mm, dan empat lapis tulangan baja diinginkan. Tulangan baja tersebut terdiri dari empat lapis dengan luas tulangan masing-masing lapis 600, 400, 400, dan 600 mm², dan ditempatkan pada jarak 50, 150, 250, dan 350 mm dari tepi beton. Dalam contoh ini, kekuatan beton dan tegangan luluh baja dianggap sebagai satu-satunya variabel acak.

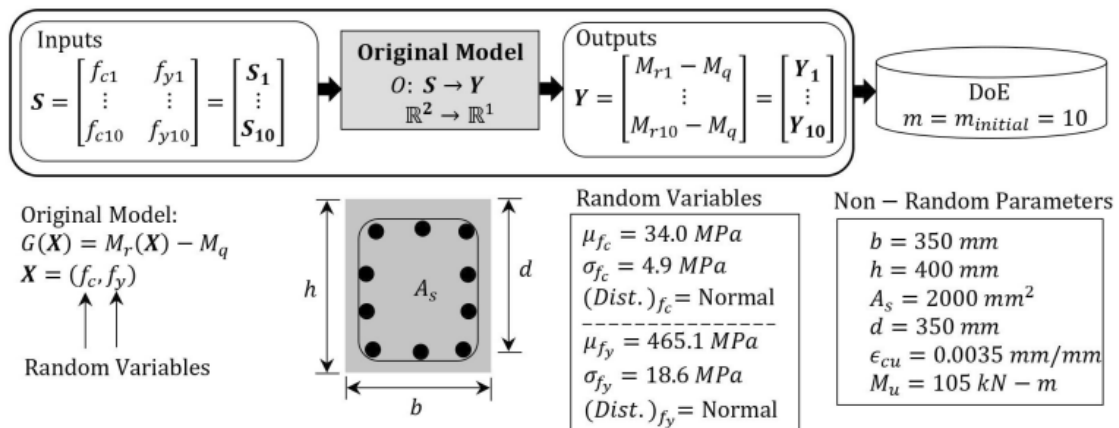
Variabel acak ini dianggap berdistribusi normal dengan nilai rata-rata kekuatan beton (f_c) dan kuat luluh baja (f_y) masing-masing sebesar 34,0 dan 465,1 MPa. Koefisien variasi (COV) kekuatan beton dan kuat luluh masing-masing dianggap sebesar 0,145 dan 0,04, yang menghasilkan simpangan baku sebesar 4,9 dan 18,6 MPa untuk kekuatan beton dan kuat luluh baja. Fungsi kinerja balok disajikan pada Persamaan 9.85.

$$G(\mathbf{X}) = M_r(\mathbf{X}) - M_q \tag{9.85}$$

dengan $G(\mathbf{X})$ adalah fungsi kinerja balok, $M_r(\mathbf{X})$ adalah resistansi balok, M_q adalah momen terfaktor yang diterapkan, dan \mathbf{X} adalah vektor variabel acak termasuk kekuatan beton (f_c) dan tegangan luluh baja (f_y).

Nilai M_q dianggap sebagai nilai tertentu sebesar $105 \text{ kN}\cdot\text{m}$. Nilai M_r adalah fungsi dari f_c dan f_y , yang dihitung berdasarkan blok tegangan Whitney per CSA A23.3 (CSA 2019) dengan regangan beton ultimit $0,0035 \text{ mm/mm}$ ($\epsilon_{cu} = 0,0035 \text{ mm/mm}$), faktor resistansi beton $0,65$ ($\phi_c = 0,65$), dan faktor resistansi baja $0,85$ ($\phi_s = 0,85$). Perlu dicatat bahwa, untuk contoh ini, faktor resistansi material dipertimbangkan di dalam fungsi resistansi, sementara untuk tujuan kalibrasi, nilai-nilai ini akan ditetapkan menjadi satu untuk model resistansi. Informasi lebih lanjut tentang perhitungan kapasitas balok beton bertulang baja (RC) dapat ditemukan dalam literatur.

Ringkasan properti penampang dan pemodelan disajikan pada Gambar 9.11. Diharapkan untuk melakukan AK-MCS dengan fungsi pembelajaran EFF guna menghitung indeks keandalan balok dalam lentur dengan karakteristik dan fungsi kinerja yang diberikan. Untuk prediktor Kriging, fungsi regresi konstan dan fungsi korelasi Gaussian dipilih. Panjang korelasi juga dioptimalkan menggunakan toolbox DACE MATLAB.



Gambar 9.11: Balok dengan dua variabel acak (Contoh 1).

Model asli untuk masalah ini adalah fungsi kinerja yang didefinisikan dalam Persamaan 9.85, dengan dua masukan (yaitu, f_y dan f_c) dan satu keluaran (yaitu, $M_r - M_q$), seperti yang ditunjukkan pada Gambar 9.11. Sebanyak 10 lokasi yang dipilih secara acak dan respons yang sesuai dipilih untuk membangun DoE awal (yaitu, $m = 10$). Oleh karena itu, ukuran matriks \mathbf{S} dan \mathbf{Y} dalam DoE masing-masing adalah 10×2 dan 10×1 , yang baris-barisnya mewakili percobaan, seperti yang ditunjukkan pada Gambar 9.11. Algoritme yang ditunjukkan pada Gambar 9.7 dilakukan dengan menggunakan kotak peralatan DACE untuk menemukan prediktor awal.

Dalam contoh ini, sejumlah total satu juta percobaan dipertimbangkan. Semua percobaan dievaluasi menggunakan fungsi pembelajaran EFF dan kandidat berikutnya untuk pembaruan dipilih sebagai lokasi yang responsnya sesuai dengan maksimum fungsi EFF. Dengan menambahkan kandidat pertama, evaluasi fungsi pembelajaran EFF disajikan pada Gambar 9.12 yang rentangnya bervariasi antara 0 hingga 3. Algoritma AK-MCS berlanjut dengan menambahkan kandidat berikutnya dan evaluasi fungsi pembelajaran selanjutnya (lihat Tabel 9.1 dan Gambar 9.8) hingga mencapai rentang maksimum 0 hingga 0,0002 setelah menambahkan 24 poin. Rentang maksimum yang terakhir memenuhi kriteria penghentian untuk fungsi EFF dari Tabel 9.1 (yaitu, maksimum 0,001), seperti yang ditunjukkan pada Gambar 9.12. Nilai fungsi EFF untuk setiap langkah analisis setelah memperbarui prediktor Kriging dengan teknik pembelajaran aktif disajikan pada Gambar 9.12.

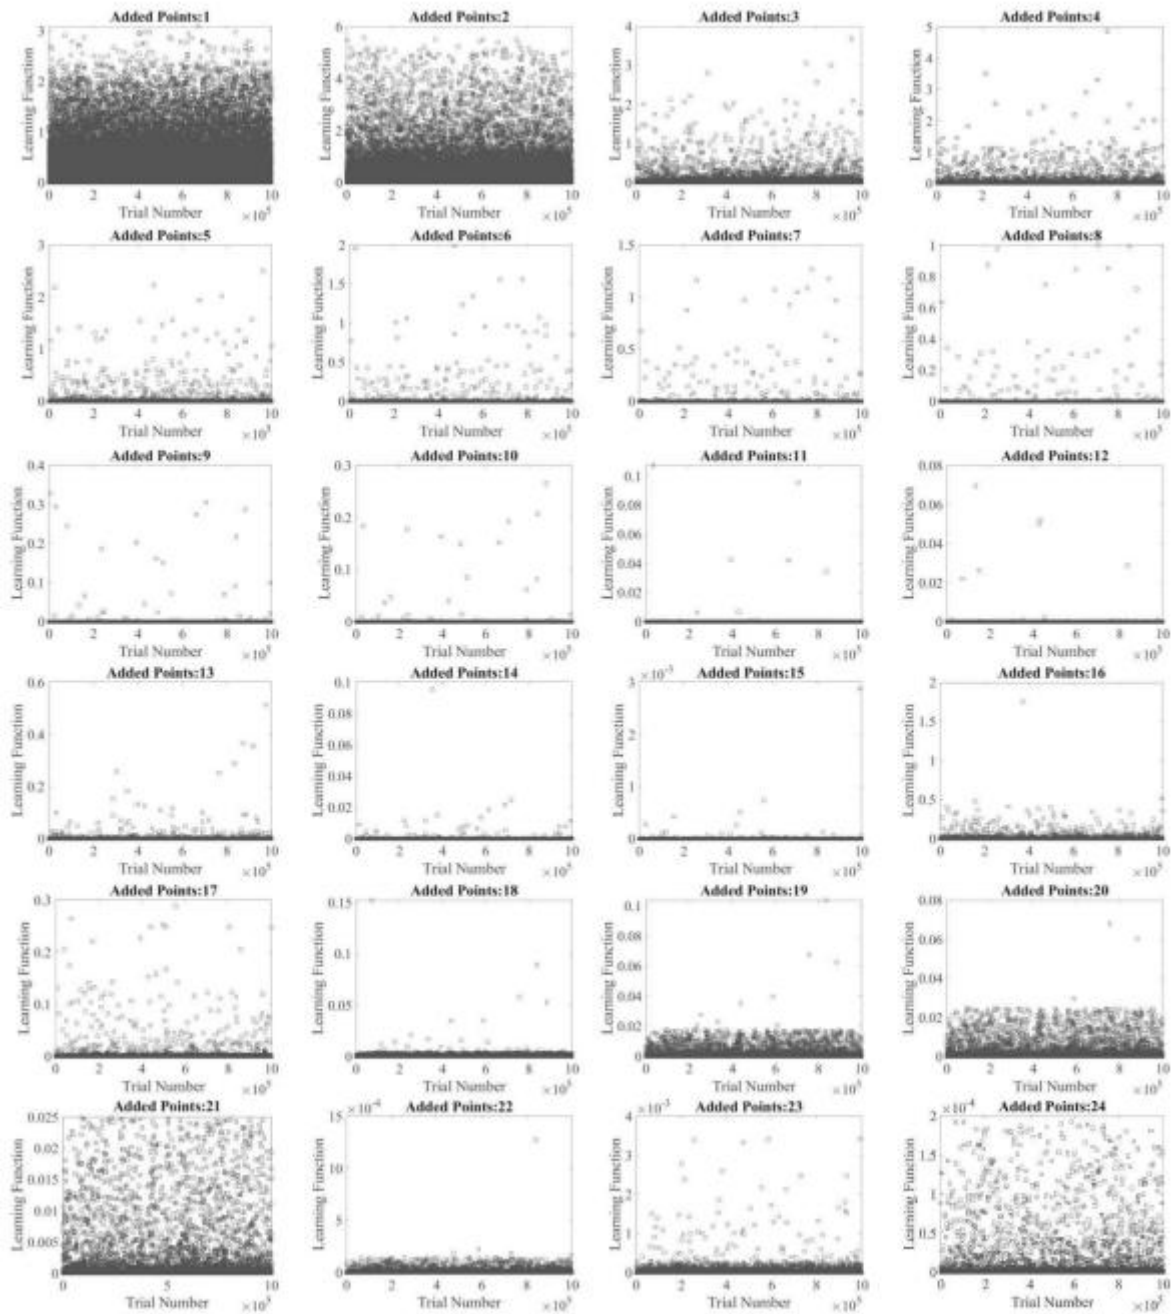
Untuk menilai akurasi metodologi, MCS dengan model asli dilakukan dengan mempertimbangkan 10^4 , 10^5 , 10^6 , 10^7 , dan 10^8 percobaan, dan indeks reliabilitas setiap analisis dibandingkan dengan AK-MCS pada Tabel 9.2. MCS dengan 10^8 percobaan dianggap sebagai analisis referensi dengan indeks reliabilitas 10^8 . Kemudian, indeks reliabilitas masing-masing analisis dibandingkan dengan analisis referensi. Kesalahan absolut menunjukkan bahwa AK-MCS dengan 10^6 percobaan memiliki kesalahan terendah (yaitu, indeks reliabilitas terdekat dengan 10^8 MCS), yang menunjukkan tingkat akurasi teknik AK-MCS yang tinggi. Perlu disebutkan bahwa untuk AK-MCS, panggilan yang diperlukan untuk fungsi kinerja hanya 24, sementara untuk mencapai tingkat akurasi yang sama dengan MCS, diperlukan lebih dari 10^7 percobaan.

Dengan kata lain, dengan AK-MCS, biaya panggilan untuk model asli serendah 0,00024% dari MCS kasar. Pengurangan substansial dalam jumlah panggilan MCS dengan menggunakan AK paling bermanfaat ketika panggilan untuk model asli tinggi, seperti menjalankan model FE untuk jembatan, bendungan, atau sistem struktur kompleks, dibandingkan dengan bagian sederhana yang dibahas dalam contoh ini. Detail AK-MCS yang berkaitan dengan Contoh 1 disajikan pada Gambar 9.13. Evolusi prediktor dari tahap pertama analisis (yaitu, menggunakan DoE awal) hingga tahap akhir analisis ditunjukkan pada Gambar 9.13(a).

Di sini, kontur hitam menunjukkan prediktor Kriging awal, prediktor Kriging akhir disajikan dalam warna, keadaan batas disajikan menggunakan garis biru, titik-titik awal ditampilkan dalam warna hitam, dan titik-titik tambahan ditampilkan sebagai titik merah. Seperti yang dapat diamati, kontur awal akurat terhadap DoE awal (yaitu, titik hitam), meskipun tidak dapat memprediksi fungsi keadaan batas secara akurat. Dengan melihat titik-titik tambahan (yaitu, titik merah), sebagian besar terletak pada garis keadaan batas (yaitu, $G(\mathbf{X}) = 0$). Nilai MSE Kriging (atau deviasi standar fungsi kinerja) pada tahap akhir analisis disajikan pada Gambar 9.13(b), dengan nilai galat minimum pada area keadaan batas karena konsentrasi titik-titik tambahan di sekitarnya.

Untuk membandingkan keadaan batas yang ditemukan oleh AK-MCS, model asli digunakan dengan grid berat yang divariasikan antara rentang variabel acak yang luas untuk menghasilkan permukaan yang sesuai dengan fungsi kinerja asli dan keadaan batasnya, seperti

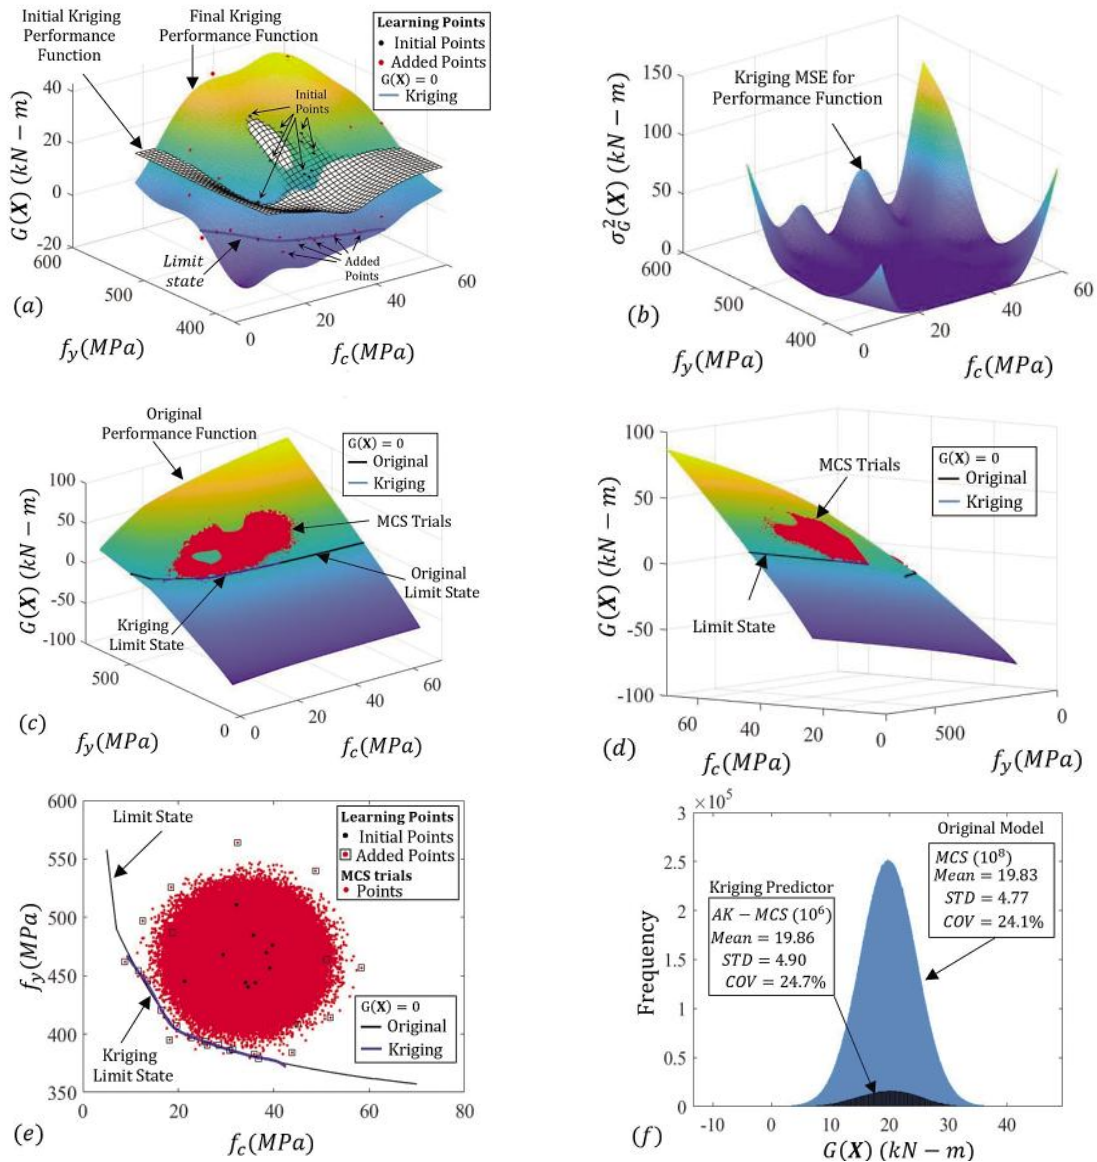
yang disajikan masing-masing pada Gambar 9.13(c) dan 9.13(d). Sebanyak 106 uji MCS untuk AK-MCS ditunjukkan sebagai titik merah pada Gambar 9.13(c) dan 9.13(d). Keadaan batas yang ditemukan dengan model asli ditunjukkan dengan warna hitam dan yang ditemukan dengan prediktor Kriging ditunjukkan dengan warna biru yang berdekatan. Untuk menunjukkan keadaan batas dan uji MCS, Gambar 9.13 mengilustrasikan hasil analisis dua dimensi. Perlu disebutkan bahwa batas keadaan yang ditemukan menggunakan AK-MCS (yaitu, garis biru) tidak diperluas sebanyak garis hitam karena daerah yang diperluas tersebut tidak diperlukan berdasarkan uji coba MCS yang tersedia (yaitu, titik merah), seperti yang ditunjukkan pada Gambar 9.13(e).



Gambar 9.12: Langkah-langkah evaluasi fungsi pembelajaran untuk Contoh 1.

Tabel 9.2: Perbandingan hasil MCS versus AK-MCS untuk Contoh 1.

Analisis	MCS (10^4)	MCS (10^5)	MCS (10^6)	MCS (10^7)	MCS (10^8)	AK-MCS (10^6)
Indeks Reliabilitas (β)	∞	4.108	4.119	4.051	4.068	4.056
Kesalahan (%)	—	0.983	1.254	0.418	0	0.295

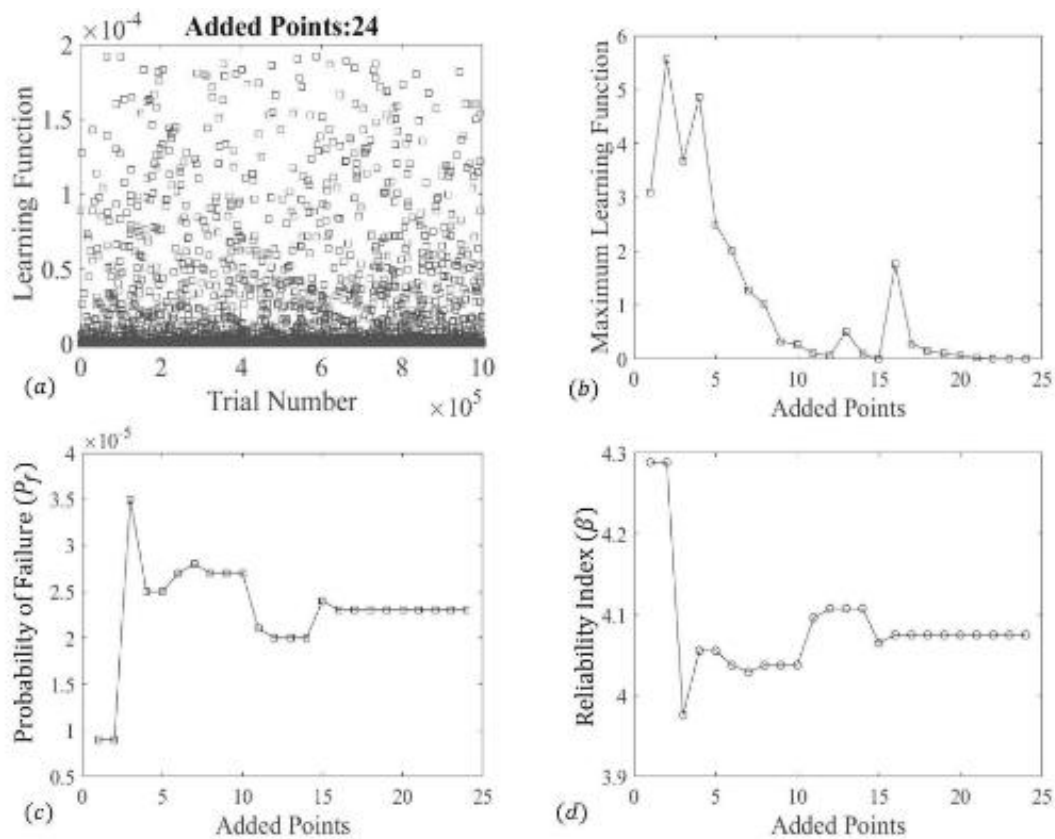


Gambar 9.13: AK-MCS: (a) Prediktor awal versus akhir; (b) kesalahan kuadrat rata-rata; (c, d) kontur fungsi kinerja asli dan keadaan batas yang diprediksi [$G(X) = 0$]; (e) kegagalan nyata versus prediksi AK-MCS; (f) histogram fungsi kinerja.

Distribusi fungsi kinerja yang diperoleh oleh AK-MCS dengan 10^6 percobaan dan MCS dengan 10^8 percobaan ditunjukkan pada Gambar 9.13(f). Perbandingan menunjukkan bahwa bentuk distribusi normal untuk kedua analisis dengan karakteristik yang sangat mirip. Rata-rata,

deviasi standar, dan koefisien variasi fungsi kinerja menggunakan AK-MCS masing-masing adalah 19,86 kN-m, 4,9 kN-m, dan 24,7%, sedangkan MCS dengan model asli masing-masing adalah 19,83 kN-m, 4,77 kN-m, dan 24,1%.

Meskipun bentuk distribusi dan karakteristiknya yang diperoleh dari AK-MCS mendekati yang diperoleh oleh MCS, fakta bahwa distribusi AK-MCS didasarkan pada model pengganti dengan akurasi tinggi yang sebagian besar mendekati fungsi keadaan batas perlu ditekankan, dan distribusi yang diperoleh oleh AK-MCS tidak boleh digunakan secara langsung tanpa verifikasi yang kuat. Untuk observasi lebih lanjut terkait analisis, Gambar 9.14 dikembangkan yang menunjukkan tahap akhir fungsi pembelajaran untuk semua uji MCS (Gambar 9.14(a)), nilai maksimum fungsi pembelajaran (yaitu, fungsi EFF) untuk semua uji MCS pada setiap uji versus jumlah titik yang ditambahkan (Gambar 9.14(b)), probabilitas kegagalan yang dihitung dengan Persamaan 9.61 untuk uji MCS pada setiap langkah (Gambar 9.14(c)), dan indeks reliabilitas versus yang dihitung dengan Persamaan 9.63 (Gambar 9.14(c)).



Gambar 9.14: Hasil AK-MCS untuk contoh 1: (a) evaluasi akhir fungsi pembelajaran dengan 24 poin tambahan; (b) fungsi pembelajaran maksimum versus poin tambahan; (c) probabilitas kegagalan versus poin tambahan; dan (d) indeks keandalan versus poin tambahan.

Perilaku fungsi pembelajaran maksimum versus titik yang ditambahkan menunjukkan tren menurun secara keseluruhan, yang berarti bahwa seiring bertambahnya jumlah titik yang baru

ditambahkan, fungsi EFF maksimum menurun hingga mencapai kriteria berhenti, seperti yang ditunjukkan pada Gambar 9.14(b).

Terdapat beberapa lonjakan lokal pada nilai maksimum yang dapat dikaitkan dengan karakteristik prediktor. Prediktor pada setiap langkah memberikan nilai rata-rata dan deviasi standar dari semua uji MCS. Untuk uji coba tertentu, rerata dan deviasi standar berubah seiring perubahan prediktor, dan hal ini dapat mengakibatkan evaluasi fungsi pembelajaran untuk prediktor tertentu yang tidak dapat ditangkap menggunakan prediktor lain yang kurang akurat. Namun, akurasi model selalu meningkat seiring dengan penambahan titik baru.

Probabilitas kegagalan dan indeks reliabilitas versus titik yang ditambahkan saling terkait (lihat Pers. 9.63). Seiring dengan peningkatan probabilitas kegagalan, indeks reliabilitas menurun, dan sebaliknya, seperti yang ditunjukkan pada Gambar 9.14(a) dan 9.14(b). Indeks reliabilitas dan probabilitas kegagalan akhirnya akan konvergen ke suatu nilai yang setelahnya penambahan titik tidak lagi meningkatkan akurasi. Konvergensi yang diperlukan dapat dinilai dengan kriteria penghentian. Untuk analisis AK-MCS, analisis ini mencakup 10^6 uji coba. Jumlah uji coba yang diperlukan akan dipilih berdasarkan probabilitas kegagalan yang diharapkan, di mana pada awalnya probabilitas kegagalan dapat diasumsikan secara subjektif. Akurasi asumsi dapat diperiksa setelah analisis, dengan mengevaluasi Pers. 9,86.

$$COV_{P_f} = \sqrt{\frac{1 - P_f}{P_f N_{MCS}}} \quad (9.86)$$

dengan COVP adalah koefisien variasi probabilitas kegagalan, P_f adalah probabilitas kegagalan, dan N_{MCS} adalah jumlah percobaan MCS.

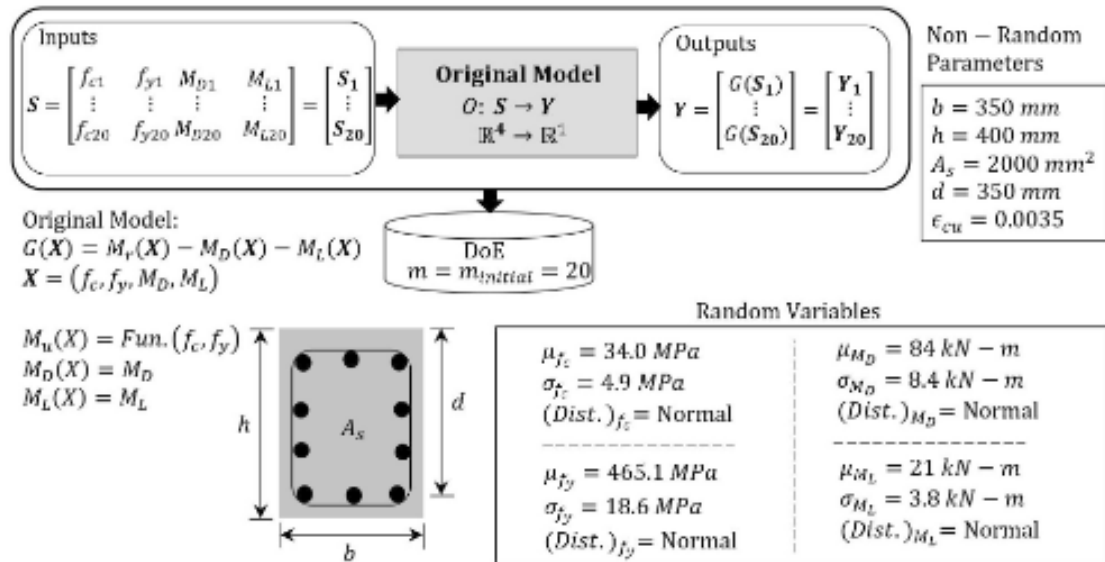
Jika COVP adalah nilai kecil, akurasi estimasi P_f dan reliabilitasnya (indf ex) dapat diterima. Dalam contoh ini, AK-MCS dengan 106 percobaan menghasilkan probabilitas kegagalan sebesar $2,496 \times 10^{-5}$ yang memiliki COV P_f sebesar 20%. Perlu dicatat bahwa nilai ini lebih tinggi daripada COVP sebesar 5% yang direkomendasikan oleh Echard dkk. (2011) untuk jumlah percobaan yang dibutuhkan. Namun, perbandingan hasil AK-MCS dan MCS pada Tabel 9.2 menunjukkan kesesuaian yang baik antara hasil MCS dan AK-MCS.

Contoh 2: Fungsi Pembelajaran yang Berbeda

Contoh ini merupakan perluasan dari Contoh 1 (Bagian 5.1), dengan perbedaan bahwa beban dianggap sebagai variabel acak. Soal ini mempertimbangkan keandalan balok pada Contoh 1 di bawah beban mati dan beban hidup tertentu dengan distribusi normal. Rata-rata dan simpangan baku untuk beban mati masing-masing adalah 84 kN-m dan 8,4 kN-m, dan untuk beban hidup, rata-rata dan simpangan baku masing-masing adalah 21 kN-m dan 3,8 kN-m, seperti yang ditunjukkan pada Gambar 9.15.

Vektor variabel acak masukan (yaitu, \mathbf{X}) untuk model awal mencakup kekuatan beton (f_c), tegangan leleh baja (f_y), beban mati (M_D), dan beban hidup (M_L). Fungsi kinerja didefinisikan dalam Persamaan 9.87.

$$G(\mathbf{X}) = M_r(\mathbf{X}) - M_D(\mathbf{X}) - M_L(\mathbf{X}) \tag{9.87}$$



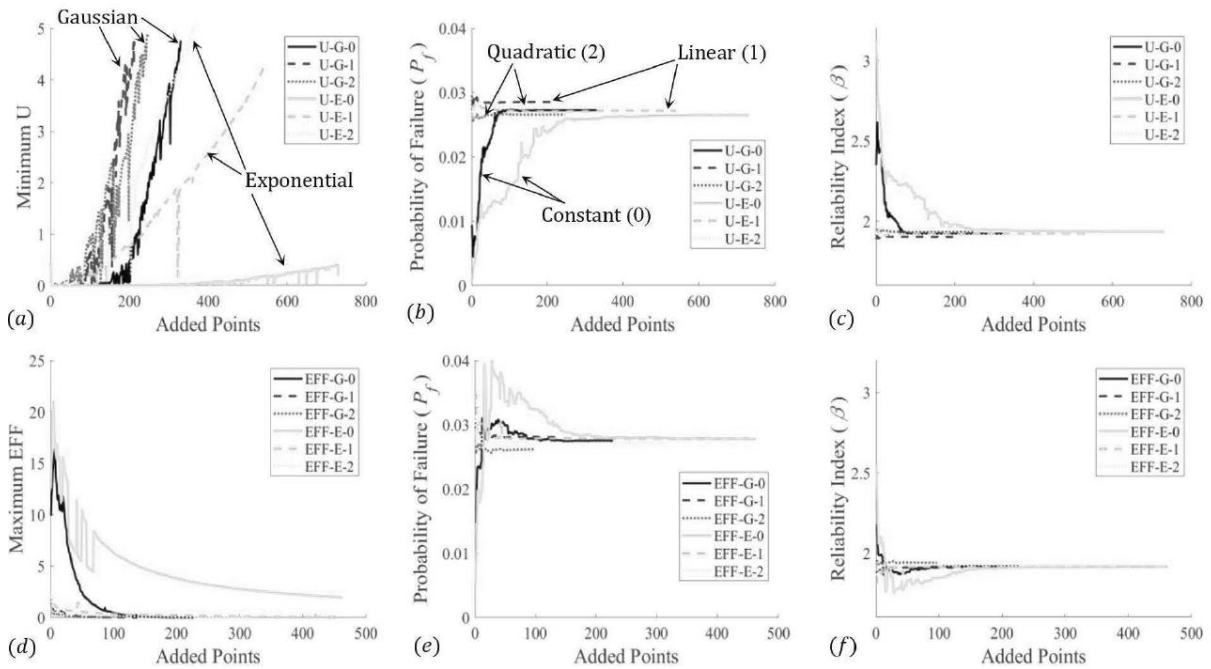
Gambar 9.15: Balok dengan empat variabel acak (Contoh 2).

Tabel 9.3: Konfigurasi untuk AK-MCS (Contoh 2).

No.	Nomor Konfigurasi	ID Konfigurasi	Fungsi Regresi	Fungsi Korelasi	Fungsi Pembelajaran
1	Konfigurasi1	U-G-0	Konstan	Gaussian	Fungsi U
2	Konfigurasi 2	U-G-1	Linear	Gaussian	Fungsi U
3	Konfigurasi 3	U-G-2	Kuadratik	Gaussian	Fungsi U
4	Konfigurasi 4	U-E-0	Konstan	Ekspensial	Fungsi U
5	Konfigurasi 5	U-E-1	Linear	Ekspensial	Fungsi U
6	Konfigurasi 6	U-E-2	Kuadratik	Ekspensial	Fungsi U
7	Konfigurasi 7	EFF-G-0	Konstan	Gaussian	Fungsi EFF
8	Konfigurasi 8	EFF-G-1	Linear	Gaussian	Fungsi EFF
9	Konfigurasi 9	EFF-G-2	Kuadratik	Gaussian	Fungsi EFF
10	Konfigurasi 10	EFF-E-0	Konstan	Ekspensial	Fungsi EFF
11	Konfigurasi 11	EFF-E-1	Linear	Ekspensial	Fungsi EFF
12	Konfigurasi 12	EFF-E-2	Kuadratik	Ekspensial	Fungsi EFF

Perhitungan momen tahanan (yaitu, M_r) sama dengan yang dijelaskan pada Contoh 1. Untuk membangun DoE awal, 20 lokasi desain dipilih secara acak, dan total 10^5 percobaan MCS dipertimbangkan untuk prosedur AK-MCS. Dalam contoh ini, 12 konfigurasi berbeda untuk AK-MCS diperiksa untuk menemukan konfigurasi optimal dengan mempertimbangkan tiga fungsi regresi, dua fungsi korelasi, dan dua fungsi pembelajaran, seperti yang disajikan pada Tabel 9.3.

Terdapat ID yang sesuai untuk setiap konfigurasi, dengan format ID A-B-C. Huruf "A" dapat berupa "U" atau "EFF" yang masing-masing sesuai dengan fungsi pembelajaran U dan EFF. Huruf "B" dapat berupa "G" atau "E" yang masing-masing sesuai dengan fungsi korelasi Gaussian dan Eksponensial, dan huruf "C" dapat berupa "0", "1", atau "2" yang sesuai dengan fungsi regresi konstan, linier, dan kuadrat.



Gambar 9.16: DoE awal yang dipilih secara acak: (a) fungsi pembelajaran minimum U versus poin tambahan; (b) probabilitas kegagalan versus poin tambahan untuk Konfigurasi1 hingga Konfigurasi6; (c) indeks keandalan versus poin tambahan untuk Konfigurasi1 hingga Konfigurasi6; (d) fungsi pembelajaran maksimum EFF versus poin tambahan; (e) probabilitas kegagalan versus poin tambahan untuk Konfigurasi7 hingga Konfigurasi12; (f) indeks keandalan versus poin tambahan untuk Konfigurasi7 hingga Konfigurasi12.

Prosedur AK-MCS yang dijelaskan secara rinci pada Contoh 1 diimplementasikan dengan memperhitungkan jumlah variabel acak yang lebih tinggi (4, bukan 2) dan fungsi kinerja yang berbeda. Hasil analisis untuk Konfigurasi1 hingga Konfigurasi6 dengan fungsi pembelajaran U disajikan masing-masing pada Gambar 9.16(a) hingga 9.16(c), sementara hasil untuk Konfigurasi7 hingga Konfigurasi12 dengan fungsi pembelajaran EFF disajikan masing-masing pada Gambar 9.16(d) hingga 9.16(f).

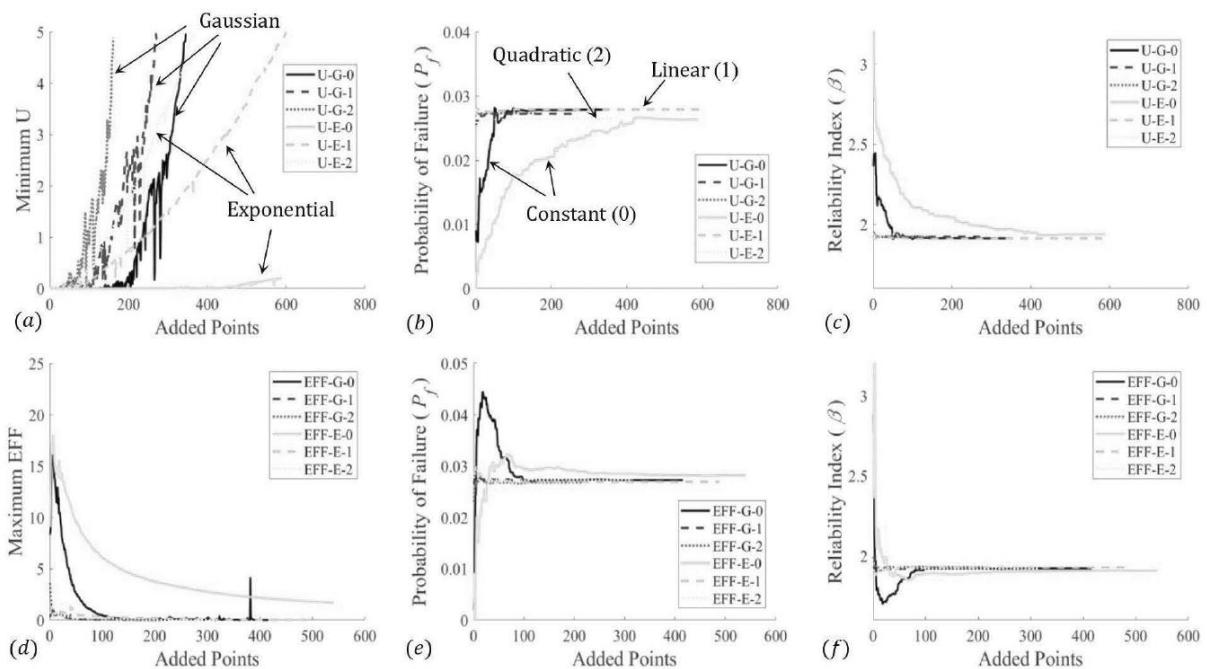
Hasil penelitian menunjukkan bahwa diperlukan beberapa poin tambahan untuk mencapai kriteria penghentian, yaitu 0,001 untuk fungsi EFF dan 2 untuk fungsi U. Untuk mengamati perilaku fungsi U secara menyeluruh, kriteria penghentian ditetapkan menjadi 5, seperti yang ditunjukkan pada Gambar 9.5(a). Perlu digarisbawahi bahwa untuk U-E-0, U-E-1, EFF-E-0, dan EFF-E-1, analisis dihentikan secara manual karena banyaknya poin tambahan dan rendahnya peluang konvergensi dalam beberapa langkah.

Probabilitas kegagalan dan indeks keandalan untuk semua konfigurasi konvergen jauh sebelum mencapai kriteria penghentian. Kriteria penghentian menunjukkan bahwa kriteria penghentian mungkin konservatif dan terdapat lebih banyak ruang untuk mengoptimalkan kriteria penghentian. Perlu juga disebutkan bahwa karena jumlah variabel acak meningkat dari dua variabel acak pada Contoh 1 menjadi empat variabel acak pada Contoh 2, jumlah titik tambahan yang diperlukan pun meningkat.

Untuk contoh ini, hasilnya juga menunjukkan bahwa penggunaan fungsi korelasi Gaussian menghasilkan konvergensi yang lebih cepat untuk fungsi pembelajaran U dan EFF dibandingkan dengan fungsi korelasi Eksponensial. Lebih lanjut, untuk fungsi korelasi Gaussian, fungsi regresi linier konvergen lebih cepat, sementara untuk fungsi korelasi Eksponensial, fungsi regresi kuadrat memberikan hasil konvergensi yang lebih baik, dengan mempertimbangkan fungsi pembelajaran U dan EFF.

Salah satu kemungkinan alasan untuk memiliki jumlah titik tambahan yang lebih besar dalam contoh ini mungkin adalah cara pemilihan DoE awal. Echard dkk. (2011) menyarankan penggunaan sejumlah kecil DoE yang dihasilkan secara acak dan memperluas DoE dengan fungsi pembelajaran, sementara Bichon dkk. (2008) menyarankan penggunaan jumlah titik minimum yang dibutuhkan untuk fungsi regresi kuadrat yang dipilih dengan LHS. Jika DoE awal dibangun menggunakan LHS, prediktor Kriging awal mungkin lebih akurat karena pemilihan DoE awal yang selektif.

Akibatnya, jumlah titik yang dibutuhkan mungkin lebih rendah, dan konvergensinya mungkin lebih cepat. Untuk menguji konvergensi dan akurasi AK-MCS yang DoE awalnya dipilih berdasarkan LHS, semua konfigurasi pada Tabel 9.3 dipelajari.

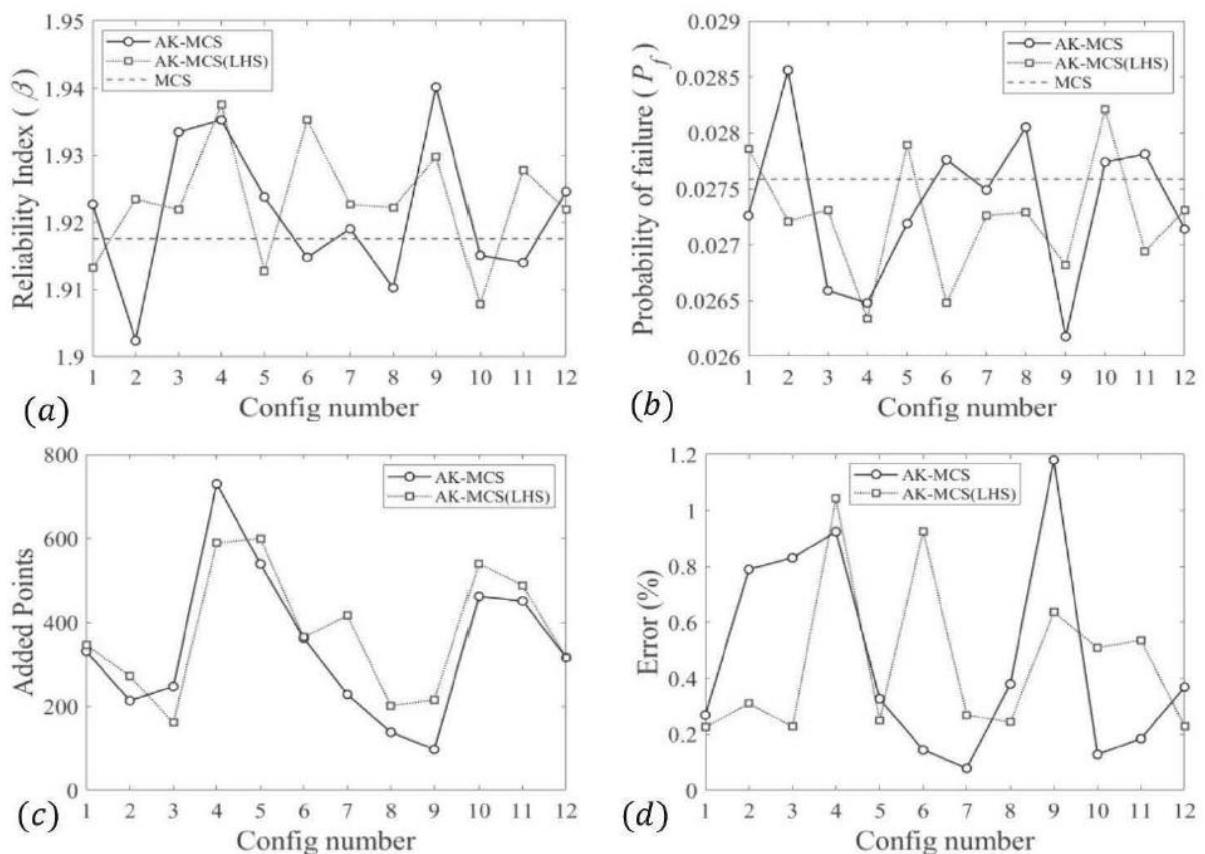


Gambar 9.17: DoE awal dipilih dengan LHS: (a) fungsi pembelajaran minimum U versus poin tambahan; (b) probabilitas kegagalan versus poin tambahan untuk Konfigurasi1 hingga Konfigurasi6; (c) indeks keandalan versus poin tambahan untuk Konfigurasi1 hingga

Konfigurasi6; (d) fungsi pembelajaran maksimum EFF versus poin tambahan; (e) probabilitas kegagalan versus poin tambahan untuk Konfigurasi7 hingga Konfigurasi12; (f) indeks keandalan versus poin tambahan untuk Konfigurasi7 hingga Konfigurasi12.

LHS adalah teknik pengambilan sampel di mana rentang setiap variabel acak masukan dibagi menjadi beberapa interval dengan probabilitas yang sama dan sampel dipilih sehingga setidaknya satu sampel dipilih dari setiap divisi dari setiap variabel acak masukan. Dalam permasalahan satu dimensi, LHS menyarankan pembagian fungsi kepadatan kumulatif (CDF) ke dalam jumlah divisi yang dibutuhkan, dan untuk permasalahan dua dimensi, LHS menyarankan pengambilan sampel dari kisi persegi (disebut kuadrat Latin) jika dan hanya jika satu sampel dipilih di setiap baris dan kolom kisi.

Untuk dimensi yang lebih tinggi, idenya berkembang dan dapat disebut Latin Hypercube. Untuk detail lebih lanjut mengenai LHS, studi referensi dapat membantu. Dalam contoh ini, DoE awal dibangun menggunakan 20 titik, yang berarti 20 sampel dari 20^4 hypercube dipilih menggunakan LHS. AK-MCS dilakukan menggunakan DoE awal dan hasilnya disajikan pada Gambar 9.17.



Gambar. 9.18: Perbandingan hasil konfigurasi yang berbeda: (a) indeks keandalan; (b) probabilitas kegagalan; (c) jumlah poin yang ditambahkan; dan (d) kesalahan absolut dalam persentase.

Gambar 9.17 menunjukkan bahwa konvergensi beberapa kasus telah meningkat, termasuk U-G-2, sementara untuk banyak kasus, tidak ada peningkatan signifikan yang diamati terkait konvergensi. Selain itu, probabilitas kegagalan dan indeks keandalan versus titik yang ditambahkan menunjukkan kurva yang lebih halus, yang berarti, dengan menggunakan LHS untuk DoE awal, variasi fungsi Kriging yang diperbarui di setiap langkah menjadi lebih halus. Dengan kata lain, prediktor Kriging antara setiap dua langkah yang berurutan kurang rentan terhadap perubahan ekstrem. Selain konvergensi, akurasi metode dibandingkan dan probabilitas kegagalan dan indeks keandalan yang sesuai dengan setiap konfigurasi yang disajikan dalam Tabel 9.3 dibandingkan dengan hasil MCS mentah dengan 106 percobaan, seperti yang disajikan dalam Gambar 9.18.

Secara keseluruhan, rentang indeks keandalan dan probabilitas kegagalan yang ditemukan oleh AK-MCS mendekati MCS mentah. Hasil menunjukkan bahwa jumlah minimum poin tambahan yang diperlukan adalah 97 untuk Konfigurasi 9 yang memberikan kesalahan tertinggi. Konfigurasi terbaik dalam hal akurasi adalah Konfigurasi 8 dengan kesalahan 0,08% yang ditemukan oleh 228 poin. Hasilnya tidak menunjukkan peningkatan akurasi menggunakan pengambilan sampel LHS untuk DoE awal kecuali untuk beberapa konfigurasi.

Perlu dicatat bahwa AK-MCS dilakukan hanya dengan menggunakan 105 percobaan dan indeks keandalan yang diharapkan rendah yang tidak memerlukan percobaan lebih lanjut untuk AK-MCS. Namun, jika indeks keandalan yang diharapkan tinggi dan probabilitas kegagalan rendah, jumlah percobaan yang lebih besar mungkin diperlukan, yang membuat perhitungan menjadi berat jika banyak poin tambahan diperlukan. Oleh karena itu, untuk menghindari biaya perhitungan yang besar, AK-MCS dapat dikombinasikan dengan metode keandalan lainnya seperti yang disajikan pada contoh berikutnya.

Contoh 3: Keandalan Balok Beton (Gabungan AK-MCS dan Importance Sampling)

Keandalan balok yang disajikan dalam Contoh 1 perlu dinilai menggunakan pendekatan keandalan dua langkah di mana nilai rata-rata beban harus ditemukan berdasarkan tahanan nominal. Sebanyak enam variabel acak dipertimbangkan, termasuk kuat beton (f_c), kuat leleh baja (f_y), beban mati (M_D), beban hidup (M_L), transformasi ke beban hidup (M_{LT}), dan faktor profesional (ϕ_p). Karakteristik statistik, distribusi, bias, dan koefisien variasi dari variabel acak serta nilai-nilai nominalnya disajikan dalam Tabel 9.4.

Tabel 9.4: Karakteristik statistik dan nilai nominal variabel acak.

Variabel Acak	Nominal	Bias	COV	Distribusi
Kuat tekan beton (f_c)	27.6	1.235	0.145	Normal
Kuat leleh baja (f_y)	413.7	1.125	0.04	Normal
Beban mati (M_D)	–	1.05	0.1	Normal
Beban hidup (M_L)	–	0.9	0.17	Gumbel
Transformasi ke beban hidup (M_{LT})	1	1	0.206	Normal
Faktor profesional (ϕ_p)	1	1.02	0.06	Normal

Nilai rata-rata beban mati dan beban hidup dapat ditentukan dengan menyamakan kapasitas nominal balok dengan momen terfaktor yang diterapkan. Kapasitas nominal dapat ditentukan menggunakan model resistansi dengan nilai nominal sebagai parameter input. Dalam contoh ini, momen terfaktor menurut CSA A23.3 (CSA, 2019) ditetapkan sama dengan kapasitas terfaktor (yaitu, dengan memasukkan faktor resistansi), seperti yang ditunjukkan pada Persamaan 9.88.

$$U_r M_n = 1.25 M_D + 1.5 M_L \quad (9.88)$$

dengan U_r adalah rasio utilisasi yang didefinisikan sebagai beban terfaktor dibagi kapasitas terfaktor, M_n adalah kapasitas terfaktor nominal, M_D adalah beban mati nominal, dan M_L adalah beban hidup nominal.

Untuk contoh ini, rasio utilisasi dianggap 1,10 yang merepresentasikan skenario pembebanan di mana seksi tersebut kelebihan beban sebesar 10% dari kapasitas terfaktor nominalnya. Selain itu, rasio beban mati terhadap beban hidup diasumsikan sebesar 4,0 menggunakan hasil survei terbaru untuk pengukuran rasio beban mati terhadap beban hidup. Penyelesaian Persamaan 11.88 menunjukkan 100,59 kN-m untuk M_n , 74,86 kN-m untuk M_D , dan 18,71 kN-m untuk M_L .

Nilai rata-rata untuk setiap distribusi dihitung sebagai nilai nominal dikalikan biasanya, dan deviasi baku setiap variabel acak dihitung sebagai nilai rata-rata dikalikan COV. Fungsi kinerja untuk contoh ini disajikan dalam Persamaan 9.89.

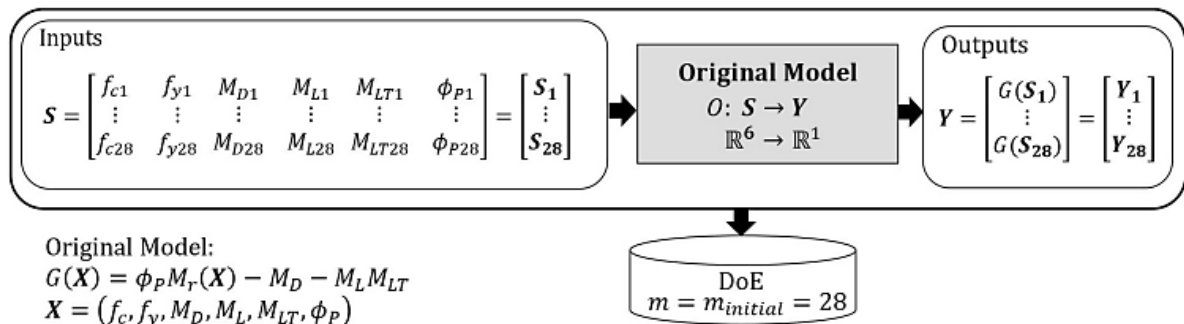
$$G(\mathbf{X}) = \phi_p \times M_r(\mathbf{X}) - M_D - M_L \times M_{LT} \quad (9.89)$$

di mana M_r adalah model resistensi yang tidak difaktorkan, yang berarti faktor resistensi beton dan baja ditetapkan sebesar 1,0 (yaitu, $\phi_c = 1,0$ dan $\phi_s = 1,0$).

Fungsi kinerja harus mencerminkan resistansi balok yang sebenarnya. Oleh karena itu, variabel acak bernama faktor profesional (ϕ_p), yang dapat dikonstruksi sebagai rasio model eksperimen terhadap model teoretis, diterapkan pada model resistansi. Seperti yang diamati pada contoh sebelumnya, dengan mempertimbangkan empat variabel acak, jumlah titik tambahan yang diperlukan cukup tinggi dengan 10^5 percobaan untuk AK-MCS. Untuk contoh ini, MCS kasar dengan 10^7 percobaan dilakukan sebagai referensi, yang menunjukkan indeks reliabilitas 4,51 untuk permasalahan balok. Jumlah percobaan yang diperlukan agar AK-MCS memberikan indeks reliabilitas 4,5 untuk fungsi kinerja normal dengan COV 20% adalah $7,36 \times 10^7$ menggunakan Persamaan 9,86. Oleh karena itu, biaya evaluasi untuk fungsi pembelajaran, pengambilan sampel dari distribusi, dan evaluasi model asli akan mahal. Untuk mengurangi biaya perhitungan, AK-MCS dengan 10^5 percobaan digunakan untuk menemukan prediktor Kriging yang dapat diimplementasikan dengan metode FORM dan IS. DoE awal dibangun menggunakan 28 lokasi desain dan responsnya yang sesuai, dengan 28 lokasi minimum yang diperlukan untuk fungsi regresi kuadrat. DoE awal disajikan pada Gambar 9.19.

Semua konfigurasi pada Tabel 9.3 dipertimbangkan untuk Contoh 3. AK-MCS dengan 10^5 percobaan dan 28 DoE yang dipilih secara acak dilakukan untuk setiap konfigurasi, tiga kali untuk menghasilkan prediktor Kriging yang berbeda. Kemudian FORM dan IS diimplementasikan untuk setiap konfigurasi tiga kali menggunakan prediktor Kriging yang ditemukan dari AK-MCS, yang masing-masing disebut AK-FORM dan AK-IS, dalam bab ini. FORM adalah pencarian berbasis gradien yang memeriksa titik-titik pada fungsi keadaan batas (yaitu, pada $G(X) = 0$) dengan iterasi untuk menemukan titik dengan jarak minimum dari titik asal ruang normal baku untuk semua variabel acak, dengan mengaproksimasikan keadaan batas dengan garis yang melewati keadaan batas pada suatu titik yang disebut titik paling mungkin (MPP). Jarak dari MPP ke titik asal ruang variabel acak normal baku disebut indeks reliabilitas Hasofer-Lind.

Perlu disebutkan bahwa untuk masalah yang sangat nonlinier, FORM mungkin menghadapi masalah konvergensi atau gagal menemukan minimum global. Prediktor Kriging memberikan permukaan yang halus dan memperbaiki masalah konvergensi. Namun, karena Kriging dilatih hanya menggunakan sejumlah titik yang terbatas, permukaan prediktor tidak andal di seluruh ruang dan akan ada ketidakakuratan dalam menemukan indeks reliabilitas menggunakan FORM dan prediktor Kriging. Perlu disebutkan bahwa untuk melakukan FORM, gradien Kriging diperlukan yang tersedia di Lampiran 9A.1. Rincian lebih lanjut tentang teori dan implementasi FORM dapat ditemukan dalam studi yang dirujuk.



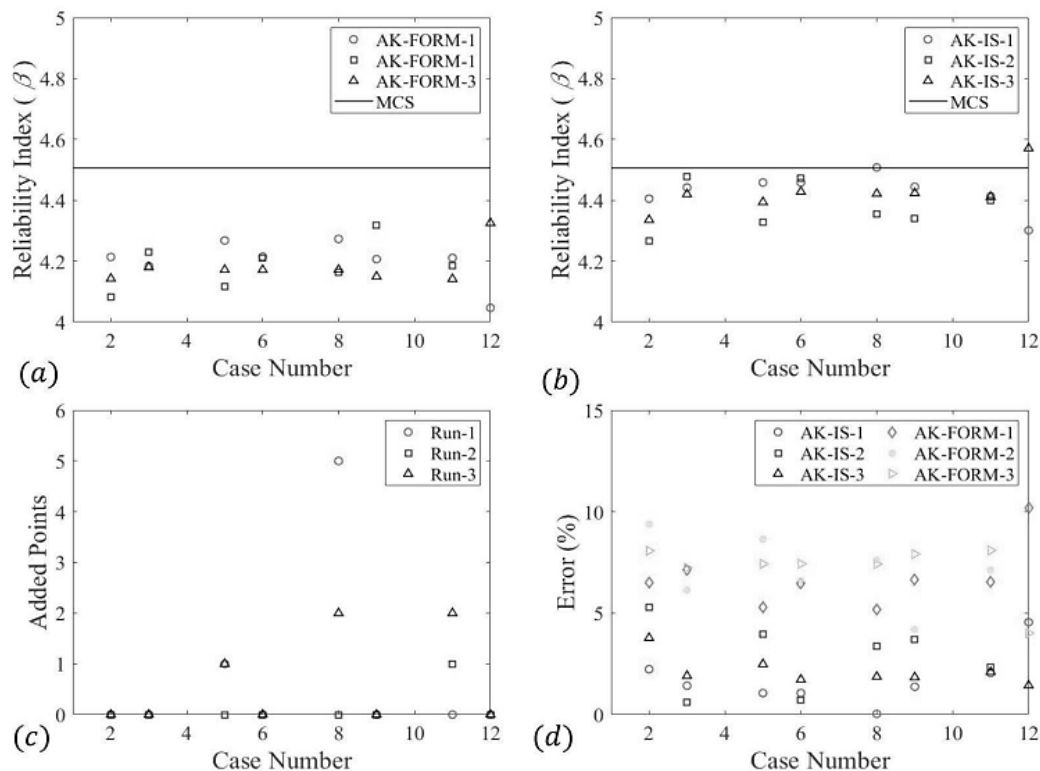
Gambar 9.19 DoE awal untuk sinar dengan enam variabel acak (Contoh 3).

Untuk mengatasi masalah ini, IS digunakan bersamaan dengan AK-MCS untuk memanfaatkan akurasi prediktor mendekati batas. MPP dapat ditemukan menggunakan AK-FORM dan MCS yang dimodifikasi dapat dilakukan dengan mengambil sampel dari distribusi normal baru (distribusi penting) yang rata-ratanya adalah MPP. Hasil yang ditemukan dengan cara ini harus dikalibrasi menggunakan bobot yang tepat untuk metode IS. Pengambilan sampel ini membantu melakukan MCS dengan jumlah percobaan yang lebih sedikit dan lebih banyak percobaan yang gagal. MPP berada pada batas dan prediktor Kriging lebih akurat mendekati batas karena ditemukan oleh prosedur AK-MCS.

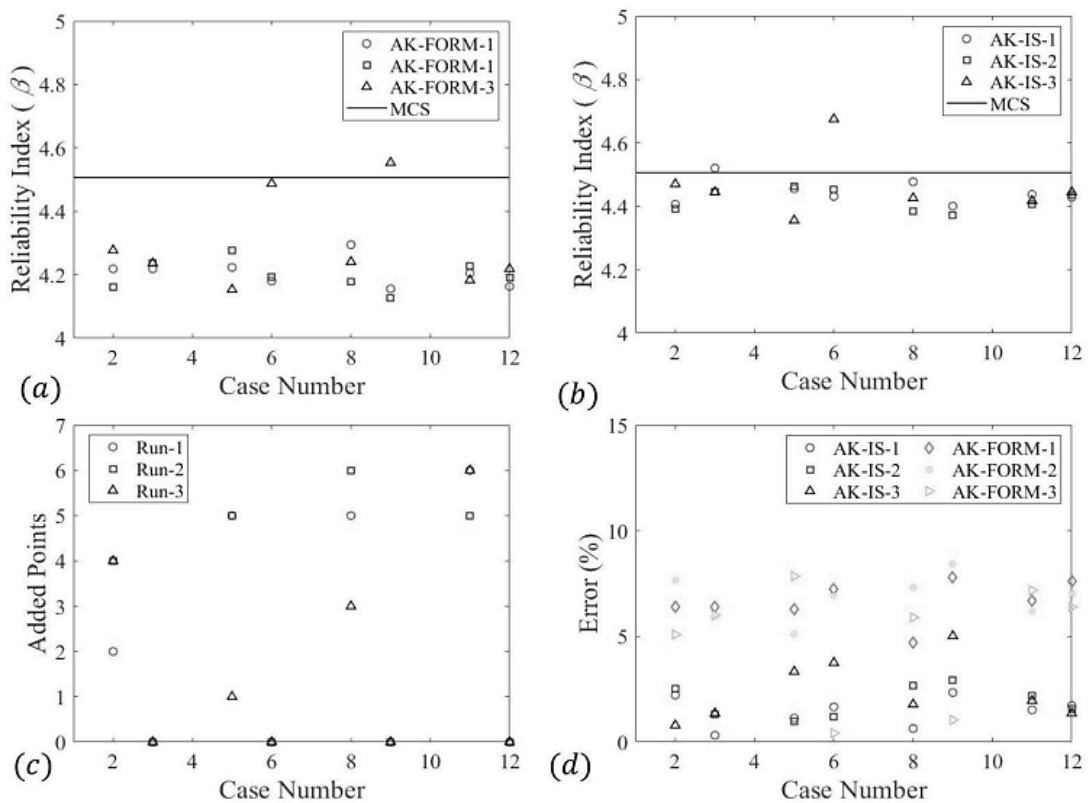
Oleh karena itu, MCS yang diambil sampelnya di sekitar MPP ini (yaitu IS) dapat menghasilkan hasil yang wajar. Rincian lebih lanjut tentang formulasi, perhitungan bobot, dan implementasi IS dapat ditemukan dalam studi-studi yang dirujuk. Dalam contoh ini, AK-MCS

dilakukan dengan 10^5 percobaan yang gagal memprediksi indeks keandalan karena tidak ada kegagalan yang teramati, dan jumlah percobaan tidak memadai. Namun, prediktor Kriging yang ditemukan pada tahap akhir AK-MCS digunakan untuk melakukan AK-FORM untuk setiap kasus analisis keandalan. MPP yang ditemukan dari AK-FORM digunakan untuk melakukan AK-IS.

Hasilnya meliputi indeks keandalan yang ditemukan untuk setiap kasus berdasarkan AK-FORM dan AK-IS, jumlah poin tambahan untuk AK-MCS awal, dan galat yang sesuai untuk setiap kasus, yang ditunjukkan pada Gambar 9.20. Hasil menunjukkan bahwa AK-FORM dapat memprediksi indeks keandalan dengan galat maksimum 10%, sementara AK-IS memiliki galat maksimum 5% yang lebih tinggi daripada galat maksimum 1,2% yang diamati pada AK-MCS pada Contoh 2 (Bagian 5.2). Namun, jumlah poin tambahan hanya 5 untuk beberapa konfigurasi yang mengurangi biaya komputasi secara substansial. Ditemukan bahwa untuk fungsi regresi konstan, prediktor Kriging gagal konvergen untuk AK-FORM, sementara berhasil digunakan untuk fungsi regresi linear dan kuadrat. Ditemukan juga bahwa untuk setiap konfigurasi, prediksi indeks reliabilitas saling berdekatan meskipun DoE awal diubah secara acak.



Gambar 9.20: Hasil analisis untuk Contoh 3: (a) AK-FORM; (b) AK-IS; (c) poin tambahan; dan (d) kesalahan (%).



Gambar 9.21: Hasil analisis untuk Contoh 3 dengan 5×10^5 percobaan: (a) AK-FORM; (b) AK-IS; (c) titik tambah; dan (d) kesalahan (%).

Perlu disebutkan bahwa akurasi prediktor terhadap fungsi kinerja merupakan fungsi langsung dari jumlah uji coba AK-MCS. Jika jumlah uji coba tidak mencukupi, ada kemungkinan titik yang ditambahkan tidak mendekati batas, atau fungsi pembelajaran tidak dapat menemukan uji coba untuk langkah berikutnya. Akibatnya, prediktor Kriging mungkin buruk jika titik yang dipilih tidak mencukupi. Untuk mempelajari pengaruh uji coba awal, studi yang sama dilakukan dengan meningkatkan jumlah uji coba dari 10^5 menjadi 5×10^5 , dan hasilnya disajikan pada Gambar 9.21.

Hasil penelitian menunjukkan bahwa dengan meningkatkan jumlah uji coba AK-MCS, prediksi indeks keandalan meningkat dan varians prediksi AK-IS menurun untuk analisis yang sesuai dengan tiga DoE awal yang berbeda. Selain itu, Konfigurasi6 menunjukkan prediksi yang sangat baik ketika jumlah uji coba meningkat. Dapat disimpulkan bahwa untuk menemukan konfigurasi terbaik, tidak diperlukan banyak uji coba. Secara keseluruhan, contoh ini membahas solusi alternatif yang menggunakan AK-MCS dan mengoptimalkannya lebih lanjut untuk mengurangi biaya perhitungan.

BAB 10

TEKNIK ESTIMASI BAYESIAN UNTUK KLASIFIKASI KERUSAKAN BERTINGKAT

10.1 PENDAHULUAN

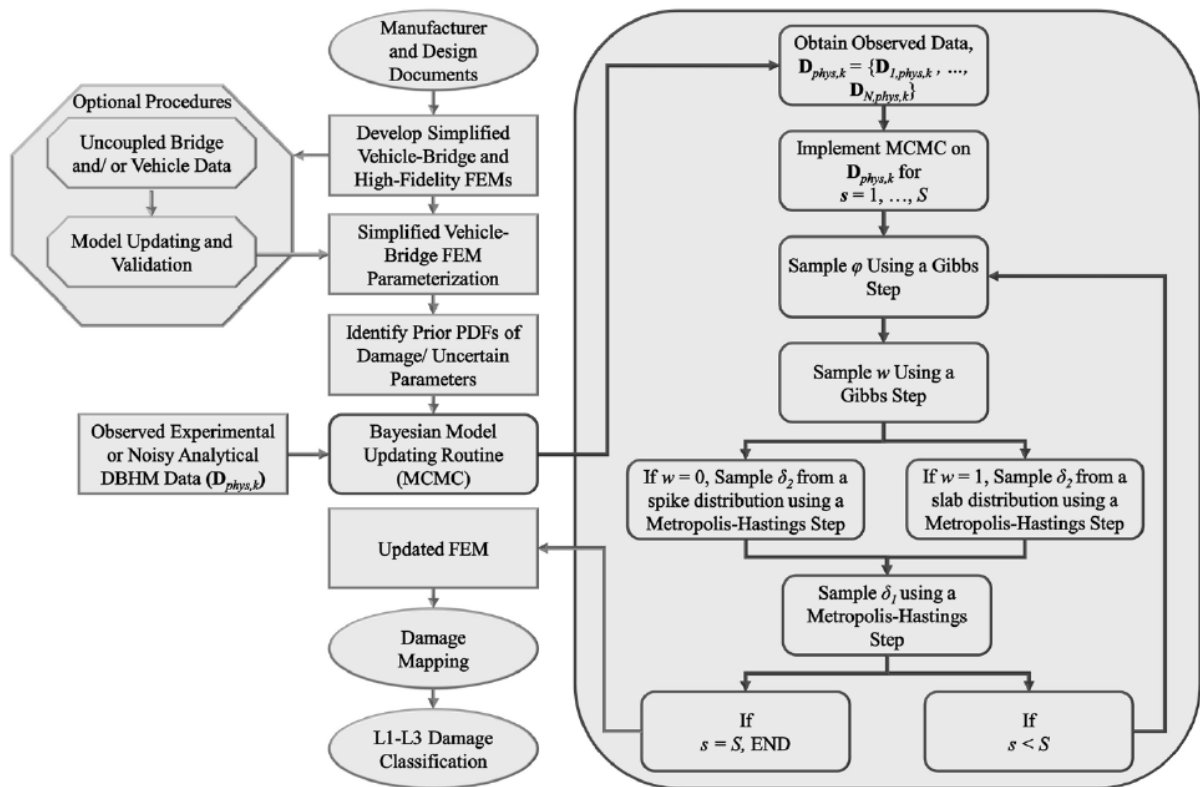
Teknik estimasi Bayesian untuk klasifikasi kerusakan menggunakan serangkaian model, termasuk FEM jembatan-kendaraan yang disederhanakan, model kerusakan (model retakan terbuka), metodologi pemetaan kerusakan untuk menghubungkan rasio retakan yang teridentifikasi dengan tingkat kerusakan fisik, serta rutinitas pembaruan model Bayesian. FEM jembatan-kendaraan yang disederhanakan tertanam dalam rutinitas pembaruan model Bayesian, yang memanfaatkan prior spike dan slab untuk melakukan klasifikasi kerusakan bertingkat.

Estimasi lokasi retakan (δ_1) dan rasio retakan (δ_2) dari rutinitas pembaruan model Bayesian dimanfaatkan oleh metodologi pemetaan kerusakan untuk mengidentifikasi rasio retakan yang ekuivalen pada FEM jembatan fidelitas tinggi dengan menghubungkan perubahan lokal dalam fleksibilitas kedua FEM. Rasio retakan yang diidentifikasi dalam FEM fidelitas lebih tinggi dianggap paling mewakili kondisi retakan sebenarnya yang ada pada struktur fisik. Gambar 10.1 menyediakan diagram alir untuk keseluruhan teknik estimasi Bayesian.

10.2 FEM KENDARAAN-JEMBATAN YANG DISEDERHANAKAN

Teknik estimasi Bayesian untuk klasifikasi kerusakan menggunakan serangkaian model, termasuk FEM jembatan-kendaraan yang disederhanakan, model kerusakan (model retakan terbuka), metodologi pemetaan kerusakan untuk menghubungkan rasio retakan yang teridentifikasi dengan tingkat kerusakan fisik, serta rutinitas pembaruan model Bayesian. FEM jembatan-kendaraan yang disederhanakan tertanam dalam rutinitas pembaruan model Bayesian, yang memanfaatkan prior spike dan slab untuk melakukan klasifikasi kerusakan bertingkat.

Estimasi lokasi retakan (δ_1) dan rasio retakan (δ_2) dari rutinitas pembaruan model Bayesian dimanfaatkan oleh metodologi pemetaan kerusakan untuk mengidentifikasi rasio retakan yang ekuivalen pada FEM jembatan fidelitas tinggi dengan menghubungkan perubahan lokal dalam fleksibilitas kedua FEM. Rasio retakan yang diidentifikasi dalam FEM fidelitas lebih tinggi dianggap paling mewakili kondisi retakan sebenarnya yang ada pada struktur fisik. Gambar 10.1 menyediakan diagram alir untuk keseluruhan teknik estimasi Bayesian.



Gambar 10.1: Urutan operasi untuk teknik estimasi Bayesian untuk klasifikasi kerusakan, termasuk validasi model awal opsional dengan data jembatan dan/atau kendaraan yang tidak terhubung.

Interaksi Kendaraan-Jembatan

Interaksi kendaraan-jembatan menggunakan prosedur dalam model yang didasarkan pada konsep elemen interaksi kendaraan-jembatan; deskripsi untuk strategi pemodelan subjek dirujuk dari literatur terkait. Dalam prosedur ini, jembatan direpresentasikan oleh model satu dimensi yang didiskritisasi menjadi sejumlah elemen balok Euler-Bernoulli (N_{ele}). Perhatikan bahwa N_{ele} bergantung pada kondisi kerusakan retak yang diterapkan, silakan lihat Bagian Model Retak Terbuka untuk detail lebih lanjut. Persamaan (10.1) menunjukkan persamaan gerak (EoM) untuk elemen balok yang ditempati oleh kendaraan:

$$(\mathbf{M}_{b,i} \ddot{\mathbf{d}}_{b,i} + \mathbf{C}_{b,i} \dot{\mathbf{d}}_{b,i} + \mathbf{K}_{b,i} \mathbf{d}_{b,i})_{t+\Delta t} = (\mathbf{f}_{be,i} - \mathbf{f}_{bc,i})_{t+\Delta t}, \quad (10.1)$$

Di mana $\mathbf{M}_{b,i}$, $\mathbf{C}_{b,i}$ dan $\mathbf{K}_{b,i}$ masing-masing adalah matriks massa, redaman, dan kekakuan elemen ke- i . Vektor $\ddot{\mathbf{d}}_{b,i}$, $\dot{\mathbf{d}}_{b,i}$, dan $\mathbf{d}_{b,i}$ masing-masing merepresentasikan percepatan, kecepatan, dan perpindahan nodal untuk elemen subjek. Gaya eksternal yang ditimbulkan dari beban mati dan pengaruh lingkungan direpresentasikan oleh $\mathbf{f}_{be,i}$, sedangkan beban kontak yang ditimbulkan oleh kendaraan direpresentasikan oleh $\mathbf{f}_{bc,i}$.

Parameter $\mathbf{K}_{b,i}$ dan $\mathbf{M}_{b,i}$ dimodelkan menggunakan matriks kekakuan tradisional dengan empat derajat kebebasan (DoF) serta matriks massa kontinu. Dalam contoh yang

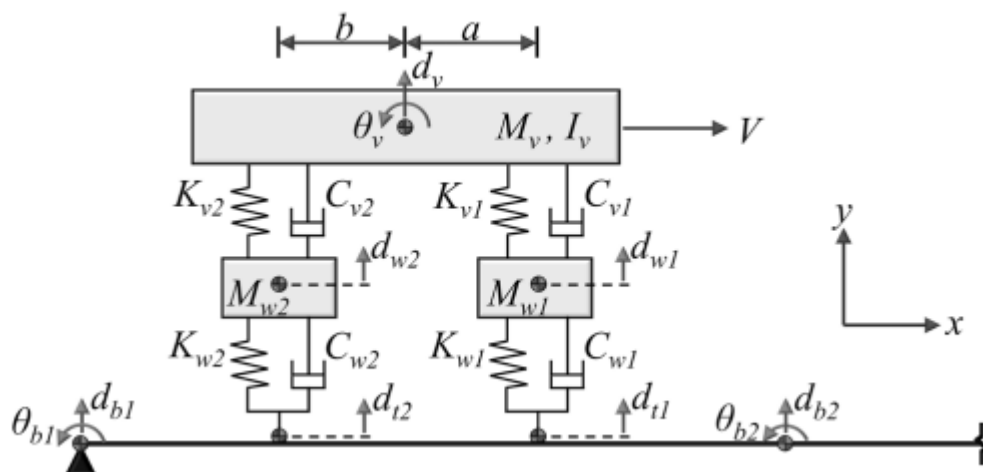
disajikan, DoF aksial diabaikan karena efek termal tidak dipertimbangkan dan kecepatan kendaraan (V) dianggap konstan; dengan demikian, gaya aksial tidak dihasilkan dari pengereman atau akselerasi. Matriks massa global (\mathbf{M}_b) dan kekakuan global (\mathbf{K}_b), beserta vektor beban eksternal global (\mathbf{f}_{be}), diperoleh dengan menggabungkan matriks dan vektor elemen lokal ketika jembatan berada dalam kondisi bebas lalu lintas. Sementara itu, matriks redaman global (\mathbf{C}_b) dihitung menggunakan metode redaman Rayleigh, yang dijabarkan dalam Persamaan (10.2) dan (10.3):

$$\mathbf{C}_b = b_0 \mathbf{M}_b + b_1 \mathbf{K}_b, \tag{10.2}$$

$$b_0 = \xi \frac{2\omega_1\omega_2}{\omega_1 + \omega_2} \quad b_1 = \xi \frac{2}{\omega_1 + \omega_2}, \tag{10.3}$$

di mana parameter b_0 dan b_1 adalah konstanta numerik yang dihitung menggunakan rasio redaman ξ dan dua frekuensi modal pertama yang tidak teredam ω_1 dan ω_2 .

Untuk menyelesaikan vektor gaya kontak global jembatan \mathbf{f}_{bc} , diperlukan EoM untuk kendaraan. Dalam contoh ini, kendaraan direpresentasikan menggunakan model setengah kendaraan enam DoF yang diuraikan pada Gambar 10.2. Model setengah kendaraan menyediakan lebih banyak lokasi untuk mengukur data riwayat waktu dibandingkan model seperempat kendaraan, yang membantu meningkatkan keandalan teknik estimasi Bayesian yang akan dibahas nanti. Untuk model setengah kendaraan, Persamaan 10.4 merepresentasikan EoM untuk kendaraan pada langkah waktu mendatang $t + \Delta t$:



Gambar 10.2: FEM jembatan-kendaraan yang disederhanakan yang dimanfaatkan untuk klasifikasi kerusakan dalam teknik estimasi Bayesian. Kendaraan direpresentasikan sebagai model setengah-kendaraan enam DoF, sementara elemen jembatan direpresentasikan sebagai elemen balok Euler-Bernoulli empat DoF tradisional.

$$\left(\begin{bmatrix} \mathbf{M}_{uu} & \mathbf{M}_{ul} \\ \mathbf{M}_{lu} & \mathbf{M}_{ll} \end{bmatrix} \begin{Bmatrix} \ddot{\mathbf{d}}_u \\ \ddot{\mathbf{d}}_l \end{Bmatrix} + \begin{bmatrix} \mathbf{C}_{uu} & \mathbf{C}_{ul} \\ \mathbf{C}_{lu} & \mathbf{C}_{ll} \end{bmatrix} \begin{Bmatrix} \dot{\mathbf{d}}_u \\ \dot{\mathbf{d}}_l \end{Bmatrix} + \begin{bmatrix} \mathbf{K}_{uu} & \mathbf{K}_{ul} \\ \mathbf{K}_{lu} & \mathbf{K}_{ll} \end{bmatrix} \begin{Bmatrix} \mathbf{d}_u \\ \mathbf{d}_l \end{Bmatrix} \right)_{t+\Delta t} = \left(\begin{Bmatrix} \mathbf{f}_{ue} \\ \mathbf{f}_{le} \end{Bmatrix} + \begin{Bmatrix} \mathbf{0} \\ \mathbf{f}_{lc} \end{Bmatrix} \right)_{t+\Delta t}, \quad (10.4)$$

di mana subskrip u merepresentasikan properti yang terkait dengan empat DoF atas pada massa pegas dan tak pegas kendaraan pada Gambar 10.2 (yaitu, d_v , θ_v , d_{w1} , dan d_{w2}), dan subskrip l merepresentasikan properti yang terkait dengan dua DoF bawah tempat kendaraan bersentuhan dengan jembatan; yaitu, d_{t1} dan d_{t2} pada Gambar 10.2. Dengan cara yang sama seperti Persamaan 10.1, vektor $\ddot{\mathbf{d}}$, $\dot{\mathbf{d}}$, dan \mathbf{d} , masing-masing, merepresentasikan percepatan, kecepatan, dan perpindahan kendaraan, sedangkan vektor gaya dengan subskrip e dan c merepresentasikan gaya eksternal dan gaya kontak kendaraan, masing-masing.

Perhatikan bahwa gaya eksternal ditetapkan sama dengan nol untuk contoh-contoh dalam bab ini dan hanya perlu dimasukkan ketika akselerasi/deselerasi kendaraan dipertimbangkan, atau eksitasi eksternal diterapkan pada kendaraan pemantau untuk lebih lanjut mengeksitasi sistem jembatan. Untuk menghitung gaya kontak kendaraan (\mathbf{f}_{lc}), akselerasi, kecepatan, dan perpindahan kendaraan atas di masa mendatang harus dianalisis terlebih dahulu; Integrasi numerik Newmark Beta dimanfaatkan dalam Persamaan 10.5–10.7 untuk menyelesaikan parameter-parameter ini pada langkah waktu mendatang:

$$\ddot{\mathbf{d}}_{u,t+\Delta t} = a_0 \Delta \mathbf{d}_u - a_1 \dot{\mathbf{d}}_{u,t} - a_2 \ddot{\mathbf{d}}_{u,t}, \quad (10.5)$$

$$\dot{\mathbf{d}}_{u,t+\Delta t} = \dot{\mathbf{d}}_{u,t} + a_3 \ddot{\mathbf{d}}_{u,t} + a_4 \ddot{\mathbf{d}}_{u,t+\Delta t}, \quad (10.6)$$

$$\mathbf{d}_{u,t+\Delta t} = \mathbf{d}_{u,t} + \Delta \mathbf{d}_u, \quad (10.7)$$

di mana vektor $\Delta \mathbf{d}_u$ merepresentasikan perubahan perpindahan kendaraan atas antara langkah waktu saat ini t dan langkah waktu mendatang $t + \Delta t$. Parameter a_0 – a_4 adalah konstanta yang digunakan untuk melakukan integrasi numerik. Konstanta ini, beserta a_5 – a_7 yang digunakan selanjutnya dalam prosedur pemodelan, dihitung sebagai berikut (Persamaan 10.8):

$$\begin{aligned} a_0 &= \frac{1}{\beta \Delta t^2} & a_1 &= \frac{1}{\beta \Delta t} & a_2 &= \frac{1}{2\beta} - 1 & a_3 &= (1 - \gamma) \Delta t, \\ a_4 &= \gamma \Delta t & a_5 &= \frac{\gamma}{t\beta} & a_6 &= \frac{\gamma}{\beta} - 1 & a_7 &= \frac{\Delta t}{2} \left(\frac{\gamma}{\beta} - 2 \right), \end{aligned} \quad (10.8)$$

β (1/4) dan γ (1/2) merepresentasikan variasi percepatan selama langkah waktu inkremental Δt , serta redaman buatan yang diperkenalkan oleh diskritisasi dalam domain waktu (Chopra, 2012; Huebner dkk., 2008). Nilai Δt sama dengan seperseribu detik ($\Delta t = 0,001$ s) untuk semua

simulasi dalam bab ini. Persamaan untuk percepatan masa depan $\ddot{\mathbf{d}}_{u,(t+\Delta t)}$, kecepatan $\dot{\mathbf{d}}_{u,(t+\Delta t)}$, dan perpindahan $\mathbf{d}_{u,(t+\Delta t)}$ dapat dimasukkan ke dalam Persamaan 10.4 untuk menyelesaikan $\Delta \mathbf{d}_u$ yang belum diketahui. Nilai $\Delta \mathbf{d}_u$ yang dihitung kemudian dimasukkan kembali ke dalam Persamaan 10.5 – 10.7 untuk menghitung secara langsung $\ddot{\mathbf{d}}_{u,(t+\Delta t)}$, $\dot{\mathbf{d}}_{u,(t+\Delta t)}$, dan $\mathbf{d}_{u,(t+\Delta t)}$.

Dengan menghubungkan percepatan, kecepatan, dan perpindahan masa depan kendaraan atas (upper vehicle) dalam bentuk langkah waktu saat ini, maka $\Delta \mathbf{d}_u$, \mathbf{f}_{lc} pada Persamaan 10.4 dapat ditentukan dengan menggunakan skema integrasi numerik Newmark-Beta untuk merumuskan ulang Persamaan Gerak (EoM) kendaraan bawah (lower vehicle) seperti yang ditunjukkan dalam Persamaan 10.9.

$$\mathbf{f}_{lc,t+\Delta t} = (\mathbf{M}_c \ddot{\mathbf{d}}_l + \mathbf{C}_c \dot{\mathbf{d}}_l + \mathbf{K}_c \mathbf{d}_l + \mathbf{p}_c)_{t+\Delta t} + \mathbf{q}_{c,t}, \quad (10.9)$$

Di mana M_c , C_c , dan K_c masing-masing adalah matriks massa, redaman, dan kekakuan kontak. Vektor p_c dan q_c merepresentasikan pengaruh gaya eksternal pada kendaraan pada langkah waktu berikutnya serta pengaruh dari vektor perpindahan kendaraan pada awal langkah waktu saat ini. Persamaan 10.10–10.14 menunjukkan bagaimana matriks dan vektor ini dihitung:

$$\mathbf{M}_c = \mathbf{L}_l^{-1} (\mathbf{M}_{ll} - \mathbf{\Psi}_{lu} \mathbf{\Psi}_{uu}^{-1} \mathbf{M}_{ul}), \quad (10.10)$$

$$\mathbf{C}_c = \mathbf{L}_l^{-1} (\mathbf{C}_{ll} - \mathbf{\Psi}_{lu} \mathbf{\Psi}_{uu}^{-1} \mathbf{C}_{ul}), \quad (10.11)$$

$$\mathbf{K}_c = \mathbf{L}_l^{-1} (\mathbf{K}_{ll} - \mathbf{\Psi}_{lu} \mathbf{\Psi}_{uu}^{-1} \mathbf{K}_{ul}), \quad (10.12)$$

$$\mathbf{p}_{c,t+\Delta t} = \mathbf{L}_l^{-1} (\mathbf{\Psi}_{lu} \mathbf{\Psi}_{uu}^{-1} \mathbf{f}_{ue,t+\Delta t} - \mathbf{f}_{le,t+\Delta t}), \quad (10.13)$$

$$\mathbf{q}_{c,t} = \mathbf{L}_l^{-1} (\mathbf{\Psi}_{lu} \mathbf{\Psi}_{uu}^{-1} \mathbf{q}_{u,t} - \mathbf{q}_{l,t}), \quad (10.14)$$

di mana \mathbf{L}_l adalah matriks identitas yang dimensinya ditentukan oleh jumlah titik kontak; yaitu, 2x2 untuk model kendaraan enam DoF pada Gambar 10.2. Parameter $\mathbf{\Psi}_{lu}$, $\mathbf{\Psi}_{uu}$, $\mathbf{q}_{u,t}$, dan $\mathbf{q}_{l,t}$ adalah parameter representatif yang digunakan untuk menyederhanakan Persamaan 10.10–10.14, dan diturunkan selama integrasi Newmark Beta dari EoM kendaraan atas dan bawah; Persamaan 10.15–10.18 memberikan ekspresi lengkap untuk parameter-parameter ini:

$$\mathbf{\Psi}_{lu} = a_0 \mathbf{M}_{lu} + a_5 \mathbf{C}_{lu} + \mathbf{K}_{lu}, \quad (10.15)$$

$$\mathbf{\Psi}_{uu} = a_0 \mathbf{M}_{uu} + a_5 \mathbf{C}_{uu} + \mathbf{K}_{uu}, \quad (10.16)$$

$$\mathbf{q}_{u,t} = (\mathbf{M}_{uu} (a_1 \dot{\mathbf{d}}_u + a_2 \ddot{\mathbf{d}}_u) + \mathbf{C}_{uu} (a_6 \dot{\mathbf{d}}_u + a_7 \ddot{\mathbf{d}}_u) - \mathbf{K}_{uu} \mathbf{d}_u)_t, \quad (10.17)$$

$$\mathbf{q}_{l,t} = (\mathbf{M}_{lu} (a_1 \dot{\mathbf{d}}_u + a_2 \ddot{\mathbf{d}}_u) + \mathbf{C}_{lu} (a_6 \dot{\mathbf{d}}_u + a_7 \ddot{\mathbf{d}}_u) - \mathbf{K}_{lu} \mathbf{d}_u)_t. \quad (10.18)$$

Untuk menghubungkan gaya kontak kendaraan \mathbf{f}_{lc} dengan gaya kontak jembatan $\mathbf{f}_{bc,i}$, $\ddot{\mathbf{d}}_l$, $\dot{\mathbf{d}}_l$ dan \mathbf{d}_l dalam Persamaan 10.9 dirumuskan ulang menjadi dalam bentuk percepatan nodal, kecepatan, dan perpindahan elemen jembatan yang ditempati Persamaan 10.19–10.21:

$$\mathbf{d}_{l,t+\Delta t} = \mathbf{n}'_s \mathbf{d}_{b,i,t+\Delta t}, \quad (10.19)$$

$$\dot{\mathbf{d}}_{l,t+\Delta t} = \dot{\mathbf{n}}'_s \mathbf{d}_{b,i,t+\Delta t} + \mathbf{n}'_s \dot{\mathbf{d}}_{b,i,t+\Delta t}, \quad (10.20)$$

$$\ddot{\mathbf{d}}_{l,t+\Delta t} = \ddot{\mathbf{n}}'_s \mathbf{d}_{b,i,t+\Delta t} + \dot{\mathbf{n}}'_s \dot{\mathbf{d}}_{b,i,t+\Delta t} + \mathbf{n}'_s \ddot{\mathbf{d}}_{b,i,t+\Delta t}, \quad (10.21)$$

di mana \mathbf{n}_s adalah vektor yang berisi fungsi bentuk polinomial Hermitian Kubik, yang digunakan untuk menurunkan matriks kekakuan elemen Euler-Bernoulli. Persamaan 10.22 menunjukkan vektor fungsi bentuk:

$$\mathbf{n}_s = \{1 - 3x_b^2 + 2x_b^3; x_c(1 - 2x_b + x_b^2); 3x_b^2 - 2x_b^3; x_c(x_b^2 - x_b)\}, \quad (10.22)$$

di mana x_c adalah posisi lokal kendaraan pada suatu elemen, dan x_b adalah koordinat lokal pada suatu elemen; yaitu, $x_b = x_c / l_e$. Perhatikan bahwa l_e merepresentasikan panjang suatu elemen dan dihitung sedemikian rupa sehingga $l_e = L / N_{ele}$, di mana L adalah panjang struktur. Setelah merumuskan kembali $\ddot{\mathbf{d}}_l, \dot{\mathbf{d}}_l, \mathbf{d}_l$ pada Persamaan 10.9 menjadi dalam $\ddot{\mathbf{d}}_{b,i}, \dot{\mathbf{d}}_{b,i}, \mathbf{d}_{b,i}$ EoM akhir untuk elemen jembatan yang terisi dapat diturunkan dengan mengalikan \mathbf{f}_c yang sekarang telah dirumuskan kembali dengan \mathbf{n}_s untuk memperoleh $\mathbf{f}_{bc,i}$. Persamaan 10.23 menunjukkan EoM akhir untuk elemen jembatan yang terisi:

$$\begin{aligned} & (\mathbf{M}_{b,i} \ddot{\mathbf{d}}_{b,i} + \mathbf{C}_{b,i} \dot{\mathbf{d}}_{b,i} + \mathbf{K}_{b,i} \mathbf{d}_{b,i})_{t+\Delta t} = \\ & (\mathbf{f}_{bc,i} - \mathbf{M}_c^* \ddot{\mathbf{d}}_{b,i} - \mathbf{C}_c^* \dot{\mathbf{d}}_{b,i} - \mathbf{K}_c^* \mathbf{d}_{b,i} - \mathbf{p}_c^*)_{t+\Delta t} - \mathbf{q}_{c,t}^* \end{aligned} \quad (10.23)$$

di mana matriks dan vektor bertanda bintang (misalnya, \mathbf{M}_c^*) adalah parameter kontak pada Persamaan 10.9 yang telah dimodifikasi oleh fungsi bentuk Hermitian Kubik. Setelah memperoleh EoM final untuk elemen jembatan yang ditempati kendaraan, matriks kontak yang dimodifikasi ditambahkan ke dalam $\mathbf{M}_{b,i}$, $\mathbf{C}_{b,i}$, dan $\mathbf{K}_{b,i}$ di ruas kiri Persamaan 10.23; matriks dan vektor elemen lokal kemudian dirangkai menjadi matriks global yang telah dirangkai sebelumnya pada koordinat globalnya masing-masing. Skema Beta Newmark kemudian digunakan untuk menyelesaikan masalah global Jembatan $\ddot{\mathbf{d}}_{b,t+\Delta t}, \dot{\mathbf{d}}_{b,t+\Delta t}, \mathbf{d}_{b,t+\Delta t}$ Nilai percepatan, kecepatan, dan perpindahan nodal untuk elemen jembatan yang ditempati kendaraan kemudian disubstitusikan ke Persamaan 10.19–10.21 untuk menghitung $\ddot{\mathbf{d}}_{l,t+\Delta t}, \dot{\mathbf{d}}_{l,t+\Delta t}, \mathbf{d}_{l,t+\Delta t}$ nilai yang dihasilkan disubstitusikan ke Persamaan 10.4 untuk menghitung $\ddot{\mathbf{d}}_{u,t+\Delta t}, \dot{\mathbf{d}}_{u,t+\Delta t}, \mathbf{d}_{u,t+\Delta t}$ Setelah percepatan, kecepatan, dan perpindahan di masa mendatang diketahui untuk bagian bawah dan atas kendaraan yang menempati jembatan, posisi global (x_g) dan lokal x_c untuk kendaraan diperbarui untuk langkah waktu berikutnya, dan analisis diulang kembali. Prosedur iteratif ini diulang hingga roda belakang kendaraan subjek mencapai ujung jembatan.

Sesuai Gambar 10.1, FEM kendaraan-jembatan yang disederhanakan diselesaikan dalam rutinitas pembaruan model Bayesian dari teknik estimasi Bayesian untuk melakukan

klasifikasi kerusakan L1–L3. Rutin pembaruan model Bayesian memanfaatkan data percepatan mentah dari DoF vertikal pegas dan tak pegas kendaraan atas (yaitu, $\ddot{\mathbf{d}}_u([\mathbf{d}_v, \mathbf{d}_{w1}, \mathbf{d}_{w2}]\mathbf{t}_{tot})$) untuk memperbarui parameter masukan model yang tidak diketahui; yaitu, δ_1 dan δ_2 .

Perhatikan bahwa t_{io} adalah vektor waktu yang berkisar dari $0 : \Delta t : T_h$, dan T_h adalah panjang total simulasi dalam detik, yang diatur oleh kecepatan kendaraan V dan total jarak yang ditempuh (D). Dalam penelitian ini, D_t adalah jumlah dari panjang jembatan L dan panjang pelat pendekat (L_o); oleh karena itu, $T_h = D/V$. Retak dimodelkan dalam model FEM kendaraan-jembatan yang disederhanakan menggunakan prosedur yang diuraikan dalam bagian berikutnya, sementara model Bayesian dibahas lebih detail dalam Bagian Rutin Pemutakhiran Model Bayesian.

Model Retak Terbuka

Kerusakan retak dimodelkan dalam FEM jembatan-kendaraan yang disederhanakan dengan menggunakan metodologi gangguan retak yang diusulkan oleh Qian dkk. deskripsi untuk strategi pemodelan subjek dirujuk dari. Metodologi yang diusulkan menggunakan mekanika fraktur untuk memberikan ekspresi empiris faktor intensitas tegangan yang dapat dimanfaatkan untuk mengaproksimasi perubahan fleksibilitas elemen. Perlu dicatat bahwa metodologi ini dapat dimodifikasi secara langsung untuk memasukkan kekakuan dan nonlinieritas redaman yang disebabkan oleh efek pernapasan.

Perhitungan peningkatan energi medan tegangan yang disebabkan oleh retak telah dipelajari secara menyeluruh dalam mekanika fraktur, dan koefisien fleksibilitas yang dinyatakan oleh faktor intensitas tegangan dapat diturunkan menggunakan teorema Castigliano ketika beroperasi dalam rentang elastis-linier. Melalui pendekatan ini, matriks fleksibilitas \mathbf{F}_L dari elemen yang retak dapat dihitung seperti yang ditunjukkan pada Persamaan. (10.24):

$$\mathbf{F}_L = \frac{1}{6EI} \begin{bmatrix} 2l_e^3 & 3l_e^2 \\ 3l_e^2 & 6l_e \end{bmatrix} + \left(\frac{18\pi(1-\nu^2)}{EWH^2} \begin{bmatrix} l_e^2 & 2l_e \\ 2l_e & 6 \end{bmatrix} \right) \int_0^{\delta_2} (\psi F_I^2(\psi)) d\psi, \quad (10.24)$$

di mana E dan ν adalah sifat-sifat material yang masing-masing mewakili modulus elastisitas dan rasio Poisson suatu elemen yang retak. Variabel W , H , dan I adalah sifat-sifat geometri yang masing-masing mewakili lebar, tinggi, dan momen inersia suatu elemen yang retak. Ukuran retak relatif diwakili oleh ψ , dan seperti yang dapat dilihat, diintegrasikan dari 0 hingga rasio retak δ_2 . Perhatikan, δ_2 didefinisikan sebagai kedalaman retakan (d_c) dibagi dengan tinggi; yaitu, $\delta_2 = d/H$. Koefisien $F^2(\psi)$ adalah faktor koreksi intensitas tegangan, yang dapat didekati seperti yang ditunjukkan dalam Pers. (10.25):

$$F_I^2(\psi) = \left(\frac{0.923 + 0.199 \left(1 - \sin\left(\frac{\pi\psi}{2}\right) \right)^4}{\cos\left(\frac{\pi\psi}{2}\right)} \right) \sqrt{\frac{\tan\left(\frac{\pi\psi}{2}\right)}{\frac{\pi\psi}{2}}}. \quad (10.25)$$

Dengan menggunakan kondisi kesetimbangan, matriks kekakuan elemen retak $\mathbf{K}_{crack,i}$ dalam keadaan bebas-bebas sekarang dapat dihitung sebagai fungsi dari matriks fleksibilitas (Persamaan 10.26):

$$\mathbf{K}_{crack,i} = \mathbf{T}'_r \mathbf{F}_L^{-1} \mathbf{T}_r, \quad (10.26)$$

di mana \mathbf{T}_r adalah matriks transformasi yang dihitung sebagai berikut (Persamaan 10.27):

$$\mathbf{T}_r = \begin{bmatrix} -1 & -l_e & 1 & 0 \\ 0 & -1 & 0 & 1 \end{bmatrix} \quad (10.27)$$

Perlu disebutkan bahwa untuk menggunakan strategi pemodelan retakan ini, retakan harus berlokasi di pusat elemen subjek; hal ini menyulitkan pembaruan δ_i secara bertahap selama rutinitas pembaruan model Bayesian sambil terus-menerus menyambung struktur dengan jumlah dan ukuran elemen yang sama. Untuk mengatasi masalah ini, skema penyambungan diadaptasi yang terus-menerus menyambung ulang struktur untuk setiap iterasi rutinitas pembaruan model Bayesian.

Selama prosedur penyambungan ulang, koordinat global dari simpul elemen yang retak pertama-tama ditetapkan sedemikian rupa sehingga berjarak sama dari δ_i yang diestimasi; koordinat global dari simpul-simpul ditetapkan sedemikian rupa sehingga $l_e = L/N_{ele}$. Setelah simpul-simpul elemen yang retak ditetapkan, bagian-bagian model yang tidak disambungkan yang tersisa dibagi secara seragam sehingga panjang elemen rata-rata kira-kira sama dengan l_e . Sebagai tindakan pencegahan, batas bawah dan atas $0,5l_e$ dan $1,5l_e$ ditetapkan untuk mencegah setiap elemen tunggal menjadi terlalu kecil atau besar.

Selain itu, N_{ele} , yang mengatur ukuran mesh rata-rata semua elemen jembatan, dipilih agar cukup besar (yaitu, $N_{ele} = 30$) sehingga untuk setiap estimasi δ_i di sepanjang jembatan, pemodelan δ_2 sebagai nol (tidak rusak) tidak menghasilkan perubahan terukur pada frekuensi jembatan hingga dua angka desimal. Sebagai tindakan pencegahan terakhir, retakan dicegah agar tidak ditempatkan dalam l dari tumpuan; hal ini dilakukan untuk menegakkan batas atas dan bawah, dan untuk memungkinkan distribusi prior untuk δ_i berperilaku sebagai distribusi normal terpotong. Secara keseluruhan, skema re-meshing subjek berfungsi dengan cara yang sama seperti skema hapus-dan-isi, pemindahan titik, dan skema meshing adaptif lainnya yang digunakan untuk mensimulasikan perambatan retakan dalam FEM fidelitas yang lebih tinggi.

Pemetaan Kerusakan

Meskipun efisiensi komputasi FEM kendaraan-jembatan yang disederhanakan membuatnya ideal untuk teknik estimasi Bayesian, terdapat kebutuhan untuk memetakan rasio retak δ_2 yang diestimasi kembali ke tingkat kerusakan fisik yang setara agar dapat menggambarkan klasifikasi kerusakan L_3 secara memadai. Oleh karena itu, disediakan metodologi pemetaan yang mengidentifikasi ukuran retak yang setara dalam FEM Abaqus fidelitas tinggi yang menghasilkan perubahan besaran fleksibilitas sistem yang sama dengan δ_2 yang diestimasi dari FEM jembatan yang disederhanakan. FEM fidelitas yang lebih tinggi lebih representatif terhadap jembatan fisik, sehingga memberikan indikasi yang lebih baik tentang kondisi retak sebenarnya yang dapat dideteksi oleh teknik estimasi Bayesian.

Perubahan fleksibilitas sistem yang disebabkan oleh kerusakan dapat dideteksi dengan membandingkan matriks fleksibilitas yang diperoleh dari bentuk moda yang sehat dan rusak, jika bentuk moda yang teridentifikasi dinormalisasi massa menjadi satu. Persamaan 10.28 dan 10.29 memberikan hubungan antara matriks fleksibilitas sistem dan sifat modal struktur:

$$\mathbf{F}_{u,d} = \phi \mathbf{\Omega}^{-1} \phi' = \sum_{m=1}^{N_{mod}} \frac{\phi_m \phi_m'}{\omega_m^2}, \quad (10.28)$$

$$\Delta \mathbf{F} = \mathbf{F}_u - \mathbf{F}_d, \quad (10.29)$$

di mana $\mathbf{F}_{u,d} \in \mathbb{R}^{l \times l}$ merepresentasikan matriks fleksibilitas yang tidak rusak atau rusak dan $\Delta \mathbf{F} \in \mathbb{R}^{l \times l}$ adalah matriks indikator kerusakan; perhatikan bahwa \mathbf{I} berkorespondensi dengan jumlah titik pengukuran sepanjang panjang jembatan. Parameter $\mathbf{\Omega} \in \mathbb{R}^{m \times m}$ adalah matriks kekakuan modal yang sama dengan $\text{diag}(1/w_m^2)$, ω_m adalah frekuensi ke- m sepanjang diagonal $\mathbf{\Omega}$, ϕ_m adalah bentuk mode ke- m th, dan N_{mod} adalah jumlah mode yang dipertimbangkan. Dalam bab ini, hanya mode pertama yang dipertimbangkan untuk menghitung perubahan fleksibilitas sistem.

Secara tradisional, para ahli telah memanfaatkan nilai maksimum absolut dari setiap kolom $\Delta \mathbf{F}$ atau diagonalnya untuk mengidentifikasi dan menemukan kerusakan pada suatu struktur, sementara pekerjaan dalam bab ini melakukan yang sebaliknya. Setelah memanfaatkan rutin pembaruan model Bayesian untuk mengidentifikasi estimasi rata-rata untuk δ_1 dan δ_2 pada FEM jembatan yang disederhanakan, $\Delta \mathbf{F}$ dihitung dan nilai yang terkait dengan δ_1 dicatat. Metodologi pemetaan kemudian digunakan untuk mengidentifikasi kedalaman retak ekuivalen yang menghasilkan nilai $\Delta \mathbf{F}$ yang sama untuk DoF yang terkait dengan lokasi longitudinal yang diberikan dalam FEM Abaqus fidelitas tinggi.

Untuk memastikan lokasi pengukuran cocok antara FEM yang disederhanakan dan fidelitas tinggi, ukuran mesh dalam FEM yang disederhanakan dipilih untuk mencocokkan dimensi longitudinal elemen-elemen dalam FEM fidelitas tinggi. Lebih lanjut, karena FEM yang disederhanakan tidak mampu menangkap variasi transversal dalam perpindahan penampang, bentuk mode yang diidentifikasi untuk setiap gelagar dalam FEM fidelitas tinggi dirata-ratakan

bersama untuk mendapatkan bentuk mode rata-rata tunggal untuk seluruh penampang. Pendekatan yang diuraikan didemonstrasikan dalam Bagian Validasi Pemetaan Model dan Kerusakan dan selanjutnya dimanfaatkan untuk menginterpretasikan hasil studi DBHM dalam Bagian Demonstrasi. Perlu dicatat bahwa metodologi pemetaan kerusakan ini dapat diterapkan pada FEM yang menggunakan model retakan terbuka atau retakan pernapasan kompleks lainnya.

Rutinitas Pembaruan Model Bayesian

Bagian sebelumnya telah menjelaskan metode mapan yang digunakan untuk memodelkan dinamika kendaraan-jembatan yang terhubung dan kerusakan retakan, serta metodologi pemetaan kerusakan baru untuk menghubungkan retakan dalam FEM yang disederhanakan dengan representasi fidelitas tinggi kerusakan jembatan. Perhatian kini beralih ke penyisipan FEM kendaraan-jembatan yang disederhanakan ke dalam rutinitas pembaruan model Bayesian untuk mendeteksi kerusakan dan mendapatkan estimasi lokasi kerusakan δ_1 dan rasio retakan δ_2 untuk metodologi pemetaan.

Kebaruan dari rutinitas pembaruan model ini adalah penggunaan distribusi *prior spike-and-slab* sebagai pendekatan deteksi kerusakan. Perlu dicatat bahwa pendekatan berbasis Bayesian yang lebih tradisional menggunakan teorema Bayes untuk deteksi kerusakan melalui pembaruan model. Spike dan slab biasanya digunakan saat mengambil sampel koefisien signifikan (*slab prior*) versus koefisien tidak signifikan (*spike prior*) dalam suatu model. Dengan mengasumsikan distribusi prior spike-and-slab pada δ_2 dalam studi ini, δ_2 dapat menyebabkan perubahan yang tidak signifikan pada model jembatan dan diambil sampelnya dari populasi sehat (*spike*), atau menyebabkan perubahan signifikan pada model jembatan dan diambil sampelnya dari populasi rusak (*slab*).

Setelah ditentukan apakah jembatan tersebut termasuk dalam populasi sehat atau rusak (memberikan klasifikasi kerusakan L_1), δ_1 dan δ_2 dapat diestimasi untuk memberikan klasifikasi kerusakan L_2 dan L_3 , masing-masing. Parameter-parameter ini awalnya diperlakukan sebagai masukan yang tidak diketahui yang diperlukan untuk menyelesaikan FEM kendaraan-jembatan yang disederhanakan. Perhatikan bahwa δ_1 dan δ_2 dibatasi pada rentang kuantitas yang layak selama pembaruan model, dengan batas bawah dan atas untuk δ_1 adalah $l_1 = l_e$ dan $u_1 = L - l_e$, dan batas bawah dan atas untuk δ_2 adalah $l_2 = 0$ dan $u_2 = 0,2$. Batas untuk δ_1 dipilih sesuai aturan yang ditetapkan untuk meshing di Bagian Retak Terbuka, sedangkan batas atas untuk δ_2 dipilih karena diasumsikan untuk pekerjaan dalam bab ini bahwa retakan harus dideteksi dan diperbaiki sebelum mencapai rasio retakan terhadap kedalaman sebesar 0,2. Untuk penyederhanaan, misalkan $\delta = (\delta_1, \delta_2)$ merepresentasikan vektor parameter yang tidak diketahui ini yang diperbarui dalam rutin pembaruan model Bayesian.

Seperti yang telah disebutkan, data akselerasi mentah dari Derajat Kebebasan (DoF) vertikal yang terpelanting dan tidak terpelanting kendaraan atas $d_u([d_v, d_{n1}, d_{n2}], t_{tot})$ dimanfaatkan dalam rutin pemutakhiran model Bayesian. Misalkan $D_{sim}(\delta, V) = d_u([d_v, d_{n1}, d_{n2}], t_{tot})$ sehingga $D_{sim}(\delta, V)$ dinyatakan sebagai fungsi dari parameter input yang tidak diketahui δ dan

kecepatan V yang diketahui. Misalkan $D_{sim,k}(\delta, V)$ menunjukkan baris ke- k dari matriks $D_{sim}(\delta, V)$. Diasumsikan (Pers. 10.30):

$$D_{n,phys,k} = D_{sim,k}(\delta, V) + \epsilon_{n,k}, \quad (10.30)$$

di mana $\mathbf{D}_{n,phys,k}$ merepresentasikan baris ke- k dari matriks observasi fisik untuk perjalanan kendaraan ke- n . Perhatikan bahwa observasi fisik diperoleh dari N perjalanan kendaraan yang berbeda (yaitu $n = 1, 2, \dots, N$), yang diasumsikan saling independen. Matriks $\epsilon_{n,k}$ terdiri dari kesalahan pengukuran dan model, yang diasumsikan terdistribusi normal dengan rata-rata nol dan kovarians $\varphi^{-1}\mathbf{I}$ sehingga kesalahan-kesalahan tersebut tidak berkorelasi. Dengan mengasumsikan $\epsilon_{n,k}$ terdistribusi normal, diasumsikan bahwa $\mathbf{D}_{n,phys,k}$ dengan input yang diketahui dan tidak diketahui juga terdistribusi normal dengan rata-rata $D_{sim,k}(\delta, V)$ dan varians $\varphi^{-1}\mathbf{I}$ seperti yang ditunjukkan dalam Pers. 10.31.

$$D_{n,phys,k} | V, \delta, \varphi \sim MVN(D_{sim,k}(\delta, V)\varphi^{-1}\mathbf{I}, \quad (10.31)$$

di mana $MVN(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ adalah distribusi normal multivariat dengan vektor rerata $\boldsymbol{\mu}$ dan matriks varians-kovarians $\boldsymbol{\Sigma}$. Dalam bab ini, diasumsikan bahwa $D_{sim,k}(\delta, V)$ menangkap respons akselerasi sebenarnya pada langkah waktu yang sesuai dengan pengukuran fisik dalam $\mathbf{D}_{n,phys,k}$. Satu-satunya perbedaan antara $D_{sim,k}(\delta, V)$ yang diperoleh dari FEM jembatan kendaraan yang disederhanakan dan $\mathbf{D}_{n,phys,k}$ yang teramati adalah kesalahan pengukuran dan model.

Asumsi ini masuk akal, karena data posisi kendaraan fisik dapat diperoleh menggunakan pelacakan GPS untuk mengidentifikasi waktu pemuatan awal kendaraan selama pengujian fisik, yang kemudian dapat digunakan untuk menyelaraskan langkah waktu. Selain itu, adaptasi dapat dilakukan pada varians $\varphi^{-1}\mathbf{I}$ untuk memasukkan korelasi dalam bentuk kesalahan melalui bentuk fungsional pada kovariansi (yaitu, dengan elemen off-diagonal bukan nol) seperti dalam. Untuk mengaktifkan estimasi Bayesian, prior berikut ditentukan pada parameter model:

$$\begin{aligned} \varphi &\sim \text{gamma}(a_0, b_0) \\ \delta_1 &\sim \text{TN}\{\mu_1, \tau_1, (l_1, u_1)\} \\ \delta_2 | w &\sim \text{TN}\{\mu_2, r(w)\tau_2, (l_2, u_2)\} \\ w | p &\sim \text{Bernoulli}(p) \end{aligned}$$

di mana $\text{TN}\{\mu, \tau, (l, u)\}$ menunjukkan distribusi normal terpotong dengan rerata μ , varians τ , dan batas (l, u) . Formulasi ini memancarkan prior spike dan slab seleksi variabel pencarian stokastik (SVSS) untuk δ_2 . SVSS dicapai melalui sakelar biner $r(w)$, yang mentransisikan prior antara spike (ketika $w = 0$) dan slab (ketika $w = 1$) dengan mengambil nilai $r(0) = r$ dan $r(1) = 1$, berturut-turut. Perhatikan bahwa parameter penyetelan r ditetapkan relatif terhadap τ_2 ;

artinya $r \ll \tau_2$, di mana τ_2 dianggap relatif besar dan ditetapkan relatif terhadap ambang batas δ_2 yang diinginkan untuk klasifikasi kerusakan L1.

Secara spesifik, $r(0)\tau_2$ ditetapkan sedemikian rupa sehingga $\sqrt[3]{r(0)\tau_2}$ (yaitu, tiga deviasi standar dari μ_2) sama dengan ambang batas δ_2 . Untuk pekerjaan dalam bab ini, ambang batas δ_2 untuk klasifikasi L1 dipilih berdasarkan sensitivitas respons kendaraan dalam model tertanam terhadap perubahan yang disebabkan oleh kerusakan pada respons jembatan dengan mempertimbangkan berbagai nilai δ_1 , kecepatan, dan tingkat kebisingan sedang.

Perlu dicatat bahwa pendekatan berbasis risiko juga dapat digunakan untuk mengidentifikasi ambang batas δ_2 yang memungkinkan deteksi kerusakan dini dan membatasi probabilitas positif palsu. Sebagaimana ditunjukkan, fitur menarik dari spesifikasi sebelumnya ini adalah bahwa klasifikasi kerusakan L1 dapat diperoleh secara langsung dengan menghitung probabilitas posterior inklusi δ_2 . Detail tentang perhitungan ini dapat ditemukan di akhir bagian ini.

Untuk memfasilitasi penyesuaian model, algoritma pengambilan sampel posterior dikembangkan. Algoritma ini mengambil realisasi dari distribusi posterior, yang diberikan oleh (Persamaan 10.32):

$$\begin{aligned}
 & p(\varphi, \delta_1, \delta_2, w, p \mid \mathbf{D}_{1,\dots,N,phys}) \propto \varphi^{\frac{3NT_{step}}{2}} \\
 & \cdot \exp \left[\frac{-\varphi \sum_{n=1}^N \sum_{k=1}^3 \{ \mathbf{D}_{n,phys,k} - \mathbf{D}_{sim,k}(\boldsymbol{\delta}, V) \}' \{ \mathbf{D}_{n,phys,k} - \mathbf{D}_{sim,k}(\boldsymbol{\delta}, V) \}}{2} \right] \\
 & \cdot \tau_1^{-\frac{1}{2}} \exp \left\{ \frac{-(\delta_1 - \mu_1)^2}{2\tau_1} \right\} \cdot \{r(w)\tau_2\}^{-\frac{1}{2}} \exp \left\{ \frac{-(\delta_2 - \mu_2)^2}{2r(w)\tau_2} \right\} p^w (1-p)^{1-w} \\
 & \cdot \varphi^{a_0-1} \exp \{-b_0 \varphi\},
 \end{aligned} \tag{10.32}$$

di mana $\mathbf{D}_{1,\dots,N,phys} = \{ \mathbf{D}_{1,phys}, \dots, \mathbf{D}_{N,phys} \}$ dan T_{step} merepresentasikan jumlah total langkah waktu dalam t_{tot} . Karena distribusi posterior tidak berada dalam bentuk yang dapat diubah (yaitu, dari keluarga distribusi yang diketahui), algoritma pengambilan sampel Markov Chain Monte Carlo (MCMC) yang terdiri dari langkah Gibbs dan Metropolis-Hastings (MH) dipertimbangkan. Secara khusus, w dan φ diambil sampelnya menggunakan langkah Gibbs karena mudah untuk mengambil sampel langsung dari distribusi kondisional lengkapnya, sementara δ_1 dan δ_2 diambil sampelnya menggunakan langkah MH karena pengambilan sampel langsung dari distribusi kondisional lengkapnya sulit. Garis besar umum langkah-langkah pengambilan sampel berikut diberikan pada Gambar 10.1. Untuk menjelaskan langkah-langkah ini, distribusi kondisional lengkap w diberikan dalam Persamaan 10.33 dan 10.34:

$$w \mid \tilde{p}, \delta_2 \sim \text{Bernoulli}(\tilde{p}), \tag{10.33}$$

$$\tilde{p} = \{ p \pi_{\delta_2}(\delta_2; \mu_2, \tau_2) \} / \{ p \pi_{\delta_2}(\delta_2; \mu_2, \tau_2) + (1-p) \pi_{\delta_2}(\delta_2; \mu_2, r\tau_2) \} \tag{10.34}$$

Perhatikan bahwa $p = 0,5$. Dalam ekspresi yang disebutkan di atas, $\pi_{\delta_2}(\cdot; \mu, \tau)$ menunjukkan kepadatan dari distribusi normal terpangkas dengan rata-rata μ dan varians τ . Demikian pula, distribusi *full conditional* dari φ diberikan dalam Pers. 10.35:

$$\varphi | \boldsymbol{\delta}, \mathbf{B} \sim \text{gamma} \left(\frac{3NT_{step}}{2} + a_0, \frac{\sum_{n=1}^N \sum_{k=1}^3 \{ \mathbf{D}_{n,phys,k} - \mathbf{D}_{sim,k}(\boldsymbol{\delta}, V) \}' \{ \mathbf{D}_{n,phys,k} - \mathbf{D}_{sim,k}(\boldsymbol{\delta}, V) \}}{2} + b_0 \right), \quad (10.35)$$

di mana input untuk distribusi gamma adalah parameter bentuk (*shape*) dan parameter skala (*scale*), secara berturut-turut. Persamaan 10.33-10.35 ditunjukkan dalam langkah-langkah pengambilan sampel g dan w menggunakan langkah-langkah Gibbs (*Gibbs steps*) pada Gambar 10.1. Akhirnya, distribusi *full conditional* dari δ_1 dan δ_2 , secara berturut-turut, diberikan oleh Pers. 10.36 dan 10.37:

$$p(\delta_1 | \mathbf{D}_{1,\dots,N,phys}, \varphi, \delta_2) \propto \exp \left[\frac{-\varphi \sum_{n=1}^N \sum_{k=1}^3 \{ \mathbf{D}_{n,phys,k} - \mathbf{D}_{sim,k}(\boldsymbol{\delta}, V) \}' \{ \mathbf{D}_{n,phys,k} - \mathbf{D}_{sim,k}(\boldsymbol{\delta}, V) \}}{2} \right] \cdot \exp \left\{ \frac{-(\delta_1 - \mu_1)^2}{2\tau_1} \right\}, \quad (10.36)$$

$$p(\delta_2 | \mathbf{D}_{1,\dots,N,phys}, \varphi, \delta_1, w) \propto \exp \left[\frac{-\varphi \sum_{n=1}^N \sum_{k=1}^3 \{ \mathbf{D}_{n,phys,k} - \mathbf{D}_{sim,k}(\boldsymbol{\delta}, V) \}' \{ \mathbf{D}_{n,phys,k} - \mathbf{D}_{sim,k}(\boldsymbol{\delta}, V) \}}{2} \right] \cdot \exp \left\{ \frac{-(\delta_2 - \mu_2)^2}{2r(w)\tau_2} \right\}, \quad (10.37)$$

Penting untuk dicatat bahwa pengambilan sampel langsung dari distribusi-distribusi ini sulit dilakukan, dan langkah-langkah *Metropolis-Hastings* (MH) harus digunakan untuk mengambil sampel dari *full conditionals* ini. Persamaan 10.36–10.37 dapat diamati pada Gambar 10.1 sebagai dua langkah MH; sebagai pengingat, δ_2 pada Gambar 10.1 diambil sampelnya dari distribusi sehat atau rusak tergantung pada nilai w saat ini. Untuk detail lengkap mengenai implementasi langkah-langkah MH, serta deskripsi langkah-demi-langkah dari seluruh rutin pengambilan sampel posterior MCMC, lihat Lampiran 10B atau referensi.

Dalam mengimplementasikan algoritma MCMC, parameter diambil sampelnya untuk $s = 1, \dots, S$ iterasi, di mana S adalah jumlah total iterasi, dengan periode *burn-in* sehingga iterasi pertama s_{hurn} dibuang dan tidak disertakan dalam estimasi dan inferensi. Periode *burn-in* memungkinkan algoritma untuk bergerak dari titik inisialisasi ke wilayah probabilitas

tinggi. *Thinning* juga dilakukan sehingga setiap s_{thin} iterat dipertahankan; hal ini dilakukan untuk mengurangi autokorelasi dalam rantai MCMC. *Burn-in* dan *thinning* dalam prosedur ini adalah praktik standar; untuk detail lebih lanjut lihat.

Setelah mengimplementasikan algoritma ini, estimasi dan inferensi posterior dilanjutkan seperti biasa; untuk diskusi lebih lanjut lihat. Secara khusus, rata-rata dari rantai nilai sampel yang dihasilkan untuk w , δ_1 , dan δ_2 diringkas sebagai estimasi yang disediakan untuk studi numerik dalam Bagian ini. Rantai MCMC dari nilai untuk w mencakup nilai sampel 0 atau 1, di mana nilai 1 menunjukkan jembatan tersebut rusak. Oleh karena itu, dengan menghitung proporsi iterasi MCMC di mana $w = 1$ (yaitu, *posterior probability of inclusion*), probabilitas jembatan rusak dan, karenanya, klasifikasi kerusakan L1 diperoleh. Perhitungan rata-rata

10.3 SISTEM JEMBATAN-KENDARAAN SUBJEK

Model setengah kendaraan dan sistem jembatan yang digunakan untuk studi numerik dalam bab ini didasarkan pada sistem jembatan dan kendaraan skala penuh yang digunakan dalam studi penelitian sebelumnya. Model setengah kendaraan yang dipilih sangat mirip dengan truk H-20 AASHTO yang digunakan untuk uji beban hidup jembatan, dan diadopsi dari penelitian sebelumnya yang berfokus pada sistem jembatan-kendaraan yang terhubung dan deteksi kerusakan retak.

Tabel 10.1 menunjukkan properti untuk model setengah kendaraan; perhatikan bahwa properti panjang kendaraan (yaitu, a dan b) sama dengan 3 m. Jembatan ini adalah jembatan gelagar baja skala penuh yang dirancang untuk pengujian laboratorium di University of Nebraska-Lincoln. Dua studi analitis dilakukan dengan jembatan subjek untuk mendemonstrasikan metodologi pemetaan kerusakan dan teknik estimasi Bayesian untuk klasifikasi kerusakan. Jembatan ini terdiri dari bentang tunggal dengan penopang sederhana sepanjang 21,3 m dan lebar 7,9 m, yang cukup untuk menampung dua lajur lalu lintas kendaraan.

Seperti yang ditunjukkan oleh penampang melintang pada Gambar 10.3, struktur atas dibangun secara komposit dengan dek beton bertulang yang bertumpu di atas tiga gelagar pelat las. Dek beton tersebut memiliki rel pembatas beton terbuka khas Departemen Jalan Raya Nebraska (NDOR). Gelagar pelat las tersebut terdiri dari sayap atas berukuran $22,86 \times 1,905$ cm, badan jembatan berukuran $137,2 \times 0,953$ cm, sayap bawah berukuran $35,56 \times 3,175$ cm untuk gelagar tengah, dan sayap bawah berukuran $35,56 \times 1,905$ cm untuk gelagar tepi.

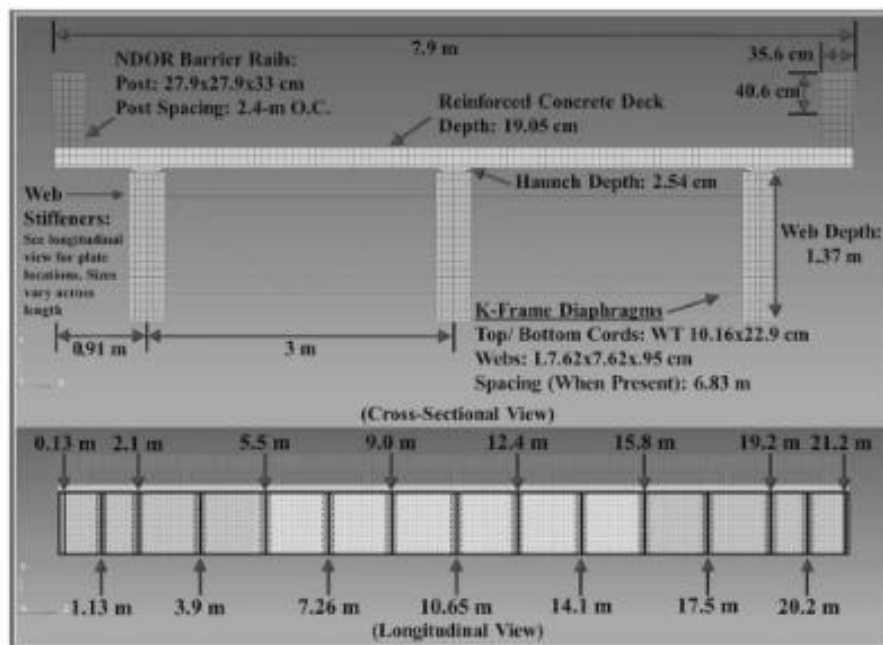
Diafragma K-Frame dipasang dengan kelipatan 6,83 m dimulai dari awal jembatan, sementara pelat pengaku geser web dipasang di lokasi yang ditunjukkan dalam tampilan longitudinal Gambar 10.3. Silakan merujuk Kathol dkk. untuk detail lebih lanjut mengenai desain dan dimensi jembatan. Untuk FEM jembatan yang disederhanakan, metode luas ekuivalen digunakan untuk merepresentasikan seluruh penampang pada Gambar 10.3 sebagai penampang ekuivalen baja. Sifat-sifat penampang ekuivalen adalah: $E = 200 \text{ GPa}$, $H = 1,9282 \text{ m}$, $W = 0,1409 \text{ m}$, $I = 0,0842 \text{ m}^4$, $\rho = 5600 \text{ kg/m}$, dan $\xi = 3\%$. Terakhir, panjang pelat pendekatan $L_a = 6,5 \text{ m}$ disertakan di kedua sisi jembatan dalam FEM jembatan-kendaraan yang

disederhanakan. Nilai L_a dipilih sedemikian rupa sehingga seluruh kendaraan dapat mulai bergerak dari anjungan dan bagian depan kendaraan dapat terus bergerak maju sementara bagian belakang tetap berada di anjungan. Perhatikan bahwa posisi awal kendaraan adalah sedemikian rupa sehingga $Dt = L + L_a$.

Tabel 10.1: Properti untuk model setengah kendaraan.

Properti Massa	Nilai	Properti Kekakuan	Nilai (kN/m)	Properti Redaman	Nilai (Ns/m)
M_v (kg)	12,404	$K_{v,1}$	1,969	$C_{v,1}$	7,182
I_v (kg/m ²)	172,160	$K_{v,2}$	728	$C_{v,2}$	2,190
M_{w1} (kg)	725	$K_{w,1}$	4,735	$C_{w,1}$	0
M_{w2} (kg)	725	$K_{w,2}$	1,973	$C_{w,2}$	0

Catatan: Frekuensi alami kendaraan yang memantul, bergerak naik turun, dan tidak bergerak masing-masing adalah 1,3 Hz, 2,2 Hz, 9,7 Hz, dan 15,4 Hz.



Gambar 10.3: Tampak penampang melintang dan memanjang jembatan gelagar baja di kampus Universitas Nebraska-Lincoln, digunakan sebagai dasar studi simulasi.

10.4 VALIDASI MODEL DAN PEMETAAN KERUSAKAN

Ringkasan validasi FEM jembatan yang disederhanakan dan fidelitas tinggi serta metodologi pemetaan kerusakan disajikan di sini. Untuk presentasi yang lebih rinci tentang studi ini, silakan lihat. FEM Abaqus fidelitas tinggi berfungsi sebagai representasi fisik struktur yang digunakan untuk memetakan rasio retak yang diestimasi untuk FEM kendaraan-jembatan yang disederhanakan kembali ke tingkat kerusakan fisik yang setara. FEM fidelitas tinggi merepresentasikan retak dengan cara yang disederhanakan menggunakan sifat material

elastis linier dengan simpul-simpul yang terputus pada sayap bawah dan sepanjang tinggi badan.

Tabel 10.2: Membandingkan defleksi statis FEM jembatan Abaqus dan yang disederhanakan terhadap pengukuran fisik.

Defleksi Tengah Jembatan Fisik wgp (Physical Bridge Mid-span Deflections)		
Diafragma Hadir	Gelagar Tengah (cm)	Gelagar Tepi (cm)
Tidak (No)	1.91	1.40
Ya (Yes)	1.75	1.45

Defleksi Tengah Abaqus FEM (Abaqus FEM Mid-Span Deflections)		
Diafragma Hadir	Gelagar Tengah (cm)	Gelagar Tepi (cm)
Tidak (No)	1.96	1.52
Ya (Yes)	1.85	1.56

Defleksi Tengah FEM Sederhana (Simplified FEM Mid-Span Deflection)	
Diafragma Hadir	Seluruh Penampang (cm)
Tidak Berlaku (N.A.)	1.75

Catatan: Defleksi statis diperoleh dari uji beban elastis ketika truk 2,5xHS-20 digunakan untuk memuat setiap lajur jembatan. Silakan merujuk Kathol dkk. (Kathol dkk., 1995) untuk detail lebih lanjut mengenai posisi beban roda depan dan belakang.

Tabel 10.3: Studi validasi yang membandingkan frekuensi FEM yang sehat dan rusak.

Abedin & Mehrabi FEM		
Kondisi Kerusakan	Frekuensi (Hz)	Perubahan Persen (%)
Sehat (Healthy)	6.00	–
Retak (Cracked)	5.00	16.67

Abaqus FEM dengan Tingkat Ketelitian Tinggi (High-Fidelity)		
Kondisi Kerusakan	Frekuensi (Hz)	Perubahan Persen (%)
Sehat (Healthy)	6.00	–
Retak (Cracked)	4.87	18.83

FEM Sederhana (Simplified FEM)		
Kondisi Kerusakan	Frekuensi (Hz)	Perubahan Persen (%)
Sehat (Healthy)	6.00	–
Retak (Cracked)	4.88	18.67

Data statis dan dinamis dari studi sebelumnya dimanfaatkan untuk memvalidasi keandalan FEM jembatan dalam bab ini. Tabel 10.2 memberikan perbandingan antara defleksi statis yang

diukur oleh Kathol dkk. dan defleksi yang diukur untuk FEM subjek dalam bab ini, sementara Tabel 10.3 memberikan perbandingan antara frekuensi sehat dan rusak yang diperoleh oleh Abedin dan Mehrabi dan frekuensi yang diidentifikasi untuk FEM subjek.

Seperti yang dapat dilihat pada Tabel 10.2, perpindahan statis Abaqus dan FEM yang disederhanakan mendekati defleksi yang diamati pada struktur fisik. Perlu dicatat bahwa karena representasi satu dimensi dari FEM jembatan yang disederhanakan, mustahil untuk menangkap variasi defleksi vertikal secara transversal; hal ini tidak dianggap sebagai masalah, karena perpindahan statis FEM yang disederhanakan berada dalam batas defleksi yang diamati pada struktur fisik.

Seperti yang dapat dilihat pada Tabel 10.3, baik FEM yang disederhanakan maupun FEM dengan fidelitas tinggi cukup menangkap perilaku dinamis sehat dan rusak dari struktur subjek yang diamati dalam penelitian sebelumnya. Untuk menunjukkan keandalan pemetaan kerusakan, metodologi ini pertama kali dimanfaatkan untuk mengidentifikasi tingkat retak yang setara pada FEM Abaqus fidelitas tinggi ketika $\delta_2 = 0,10$ diterapkan di tengah bentang ($\delta_1 = 10,65$ m) pada FEM yang disederhanakan. Karena retakan dapat terjadi pada satu girder atau secara bersamaan pada beberapa girder dari suatu struktur fisik, beberapa skenario perlu dipetakan dalam FEM Abaqus fidelitas tinggi.

Dalam bab ini, tiga skenario kerusakan (DS_1 – DS_3) dipertimbangkan pada FEM Abaqus: DS_1 retakan terjadi secara merata pada semua girder, DS_2 retakan tunggal terjadi pada girder interior, dan DS_3 retakan tunggal terjadi pada salah satu girder eksterior. Selama analisis pemetaan, rasio retak ekuivalen sebesar 0,0035, 0,0162, dan 0,0180 diidentifikasi untuk DS_1 – DS_3 , masing-masing, untuk memperkenalkan perubahan puncak yang sama dalam fleksibilitas (yaitu, $\Delta F = 2,75e^{-10}$) pada FEM Abaqus fidelitas tinggi seperti FEM yang disederhanakan untuk lokasi yang terkait dengan $\delta_1 = 10,65$ m.

Selain itu, masing-masing rasio retak yang diidentifikasi menangkap frekuensi jembatan fundamental yang rusak sebesar 5,95 Hz dan perubahan umum dalam fleksibilitas di sepanjang struktur. Perhatikan bahwa ketika membandingkan bentuk mode fundamental dari FEM yang disederhanakan dan Abaqus, ditentukan bahwa bentuk mode yang sehat dan yang rusak berada dalam kesepakatan yang sangat baik, dengan nilai kriteria jaminan modal (MAC) sebesar 0,999 yang menunjukkan konsistensi yang hampir sempurna antara FEM. Kesesuaian antara bentuk mode yang sehat dan yang rusak menunjukkan bahwa metode penghitungan bentuk mode rata-rata untuk FEM fidelitas tinggi selama pemetaan kerusakan adalah wajar.

10.5 DEMONSTRASI TEKNIK ESTIMASI BAYESIAN UNTUK DBHM

Bagian ini memberikan serangkaian contoh untuk menunjukkan keandalan teknik estimasi Bayesian untuk klasifikasi kerusakan. Studi simulasi dilakukan dengan menghasilkan data 'fisik' $D_{n,phys,k}$ untuk sejumlah kondisi kerusakan dan kondisi operasi. Selain itu, hasil klasifikasi L2 dan L3 dari studi simulasi dimanfaatkan dalam metodologi pemetaan kerusakan untuk memberikan indikasi rasio retak fisik yang dapat dideteksi oleh teknik estimasi Bayesian.

Cakupan

Sebuah studi dasar dilakukan untuk menunjukkan akurasi klasifikasi kerusakan L1–L3 dari teknik estimasi Bayesian untuk rasio retak sebesar 0,05 pada lokasi 2,1, 5,5, dan 10,65 m dari tumpuan kiri jembatan sepanjang 21,3 m. Lokasi-lokasi ini dipilih berdasarkan keberadaan sambungan las untuk pengaku geser dan diafragma yang diuraikan dalam tampak memanjang pada Gambar 10.3. Berdasarkan Manual Referensi Inspektur Jembatan, sambungan las, terutama yang berada pada permukaan tarik, rentan terhadap retak leleh akibat kombinasi cacat fabrikasi dan tingkat tegangan yang tinggi. Perhatikan bahwa $\delta_2 = 0,05$ untuk semua studi DBHM dalam bab ini.

Studi juga dilakukan untuk menunjukkan dampak derau dan kuantitas data eksperimen N terhadap akurasi klasifikasi L1–L3 ketika $\delta_1 = 2,1$, dan 10,65 m. Untuk studi dasar, N ditetapkan menjadi satu, V ditetapkan menjadi sedang 15,66 m/s, dan tingkat derau rendah ditambahkan ke setiap vektor respons sehingga rasio sinyal terhadap derau (SNR) rata-rata sebesar 30 dB tercatat di setiap DoF dalam $D_{l,phys,k}$. SNR dihitung seperti yang ditunjukkan pada Persamaan 10.38:

$$SNR = 20\text{Log}_{10} \left(\frac{A_s}{A_n} \right), \quad (10.38)$$

di mana A_s dan A_n masing-masing mewakili akar kuadrat rata-rata dari respons akselerasi bersih dan vektor derau. Simulasi dengan SNR 20 dan 10 dB juga dilakukan untuk menunjukkan dampak peningkatan tingkat derau terhadap klasifikasi kerusakan. Rentang nilai SNR subjek dipilih karena mewakili tingkat derau aditif yang biasanya digunakan untuk studi SHM. Persamaan (10.38) dirumuskan ulang untuk menghitung A_n yang diperlukan untuk mencapai rasio derau ini (Persamaan 10.39):


$$A_n = \frac{A_s}{10^{\frac{SNR}{20}}}. \quad (10.39)$$

Oleh karena itu, diasumsikan bahwa $\epsilon_{n,k} \sim \text{MVN}(0, A_n \cdot I)$ sehingga $\phi^{-1} = A_n$ di semua konfigurasi simulasi. Gambar 10.4 menunjukkan bagaimana respons akselerasi DoF kendaraan berpegas dan tidak berpegas berubah untuk SNR 10, 20, dan 30 dB. Untuk menunjukkan dampak N terhadap klasifikasi kerusakan L1–L3, $D_{n,phys,k}$ diperoleh untuk N yang sama dengan 5, 10, 15, dan 20 kali uji coba dan rata-rata multi-uji coba diambil untuk setiap DoF kendaraan. Pengujian dilakukan menggunakan V ideal yang ditentukan oleh studi kecepatan untuk $\delta_1 = 2,1$ m dan SNR 10 dB dan 20 dB. Dalam semua konfigurasi studi simulasi, hiperparameter pada distribusi prior φ diasumsikan sebagai $a_0 = 1$ dan $b_0 = 0$ sehingga prior tersebut kurang informatif, sehingga $D_{n,phys,k}$ dapat memberikan informasi lebih lanjut kepada model.

Karena retak fatik kemungkinan besar terjadi di daerah lentur yang lebih tinggi dan lebih dekat ke pusat jembatan, δ_1 diasumsikan memiliki distribusi prior dengan $\mu_1 = 10,65$ m dan batas $L1 = 0,72$ m dan $u_1 = 20,58$ m. Varians ditetapkan sebesar $\tau_1 = 12,60 \text{ m}^2$, sehingga awal dan akhir jembatan berada sekitar tiga standar deviasi dari rata-rata. Dari analisis

sensitivitas yang dilakukan pada FEM kendaraan-jembatan yang disederhanakan, $\delta_2 = 0,015$ merupakan rasio retak terkecil yang menyebabkan perubahan yang terukur secara wajar pada data respons kendaraan. Untuk menetapkan $\delta_2 = 0,015$ sebagai ambang batas klasifikasi kerusakan L1, τ_2 ditetapkan sebesar 100 dan $r(0)$ ditetapkan sebesar $2,5 \times 10^{-7}$. Dalam studi ini, $\delta_2 = 0,015$ terletak tiga deviasi standar dari $\mu_2 = 0$; yaitu, $3\sqrt{(2.5e - 7)100} = 0.015$ Lihat Gambar 10.5 untuk representasi visual dari distribusi prior spike dan slab yang digunakan.


Untuk melakukan estimasi dan inferensi posterior, algoritma pengambilan sampel posterior digunakan untuk mengambil $S = 16.000$ sampel MCMC dengan periode pembakaran $\text{sburn} = 1.000$ iterasi. Untuk mengurangi efek autokorelasi, penipisan dilakukan sedemikian rupa sehingga setiap $\text{sthin} = \text{iterasi ke-15}$ dipertahankan, menyisakan 1.000 sampel untuk dianalisis. Jumlah iterasi dipilih untuk memastikan bahwa setelah periode burn-in dan thinning, rantai posterior yang cukup besar tercapai untuk estimasi dan inferensi titik yang reliabel.



Gambar 10.4: Respons akselerasi DoF berpegas kendaraan (d_v) dan DoF tak berpegas depan (d_{w1}) saat mempertimbangkan SNR 10, 20, dan 30 dB.

Dalam studi data simulasi ini, data eksperimen yang berisik ($D_{n,phys,k}$) dihasilkan dengan jumlah pengujian $N = 1, 5, 10, 15$, atau 20 kali uji jalan sebelum algoritma MCMC (Markov Chain Monte Carlo) dijalankan. Hal ini setara dengan memperoleh data eksperimen dari 1, 5, 10, 15, atau 20 kali lintasan kendaraan fisik pada jembatan. Setelah algoritma MCMC diinisialisasi, proses pengambilan sampel hanya bergantung pada pelaksanaan FEM jembatan-kendaraan. Untuk setiap skenario kerusakan yang dipelajari dalam bab ini, sebanyak 100 set data disimulasikan dan dianalisis. Artinya, 100 kali operasi seperti yang digambarkan pada Gambar 10.1 dieksekusi.

Pembuatan 100 set data simulasi ini bertujuan untuk memvalidasi metodologi, yaitu memastikan bahwa estimasi rata-rata yang diperoleh cukup mendekati nilai kebenaran. Perlu dicatat bahwa jika digunakan satu set data eksperimen nyata dari uji DBHM fisik, maka operasi yang ditunjukkan pada Gambar 10.1 hanya perlu dilakukan satu kali untuk memperbarui FEM jembatan-kendaraan yang disederhanakan dan menghasilkan klasifikasi kerusakan L1–L3.



Gambar 10.5: Contoh yang menunjukkan distribusi spike dengan $\mu_2 = 0$ dan simpangan baku 0,005 (yaitu, $\sqrt{r(0)\tau_2} = \sqrt{(2.5e - 7)100}$) dan distribusi slab dengan $\mu_2 = 0$ dan simpangan baku 10; yaitu, $\sqrt{r(1)\tau_2} = \sqrt{(1)100}$) Ketika $w = 0$, jembatan dianggap sehat dan δ_2 diambil sampelnya dari distribusi spike. Ketika $w = 1$, jembatan dianggap retak dan δ_2 diambil sampelnya dari distribusi slab.

Hasil studi simulasi dirangkum dalam bagian-bagian berikut. Secara khusus, hasil yang disajikan merupakan estimasi rata-rata posterior untuk δ_1 dan δ_2 . Untuk mengkuantifikasi ketidakpastian, estimasi rata-rata deviasi standar posterior (SSD) juga diberikan. Terakhir, untuk menilai efikasi model terhadap klasifikasi kerusakan L1, estimasi rata-rata probabilitas inklusi posterior (PI) juga diberikan.

Studi Dasar

Sebagaimana dapat dilihat pada Tabel 10.4, klasifikasi kerusakan L1 100% dicapai di setiap lokasi kerusakan untuk kasus dasar di mana data dikumpulkan dari satu kendaraan yang berjalan pada kecepatan $V = 15,66$ m/s dan SNR 30 dB. Hasil ini menunjukkan bahwa untuk tingkat kebisingan yang rendah, teknik estimasi Bayesian tidak hanya mampu mendeteksi retakan subjek ($\delta_2 = 0,05$) dengan kepastian absolut, tetapi juga mengidentifikasi lokasi dan besarnya dengan akurasi dan presisi tinggi di sepanjang struktur.

Untuk studi dasar, DS_1 – DS_3 yang diuraikan dalam Bagian Pemetaan Kerusakan untuk Abaqus FEM fidelitas tinggi dimanfaatkan untuk memetakan estimasi δ_2 untuk lokasi kerusakan 2,1 dan 10,65 m. Untuk setiap skenario kerusakan pada Tabel 10.5, baik nilai δ_2 sebenarnya dan estimasi δ_2 dari studi DBHM dasar dipetakan ke rasio retak ekuivalen (didefinisikan secara konsisten dengan bagian) pada FEM fidelitas tinggi. Seperti yang dapat dilihat pada Tabel 10.5, perbedaan halus antara kebenaran dan estimasi pada model yang disederhanakan ketika $\delta_2 = 0,05$ tidak menghasilkan perbedaan yang signifikan antara kebenaran dan estimasi yang dipetakan pada FEM Abaqus, yang menunjukkan bahwa estimasi akurat untuk kondisi retak sebenarnya pada struktur fisik masih dapat diperoleh jika estimasi model yang disederhanakan sedikit tidak akurat. Untuk menunjukkan secara visual bahwa rasio retak yang dipetakan menyebabkan perubahan yang sama dalam fleksibilitas seperti $\delta_2 = 0,05$ pada model yang disederhanakan, Gambar 10.6 menunjukkan seberapa baik rasio retak

yang diestimasi menangkap ΔF puncak dan perubahan umum dalam fleksibilitas di sepanjang struktur jika dibandingkan dengan FEM yang disederhanakan.

Tabel 10.4: Hasil klasifikasi kerusakan L1-L3 saat $N = 1$, $V = 15,66$ m/s, dan SNR 30 dB.

	L2: δ_1 (m)	L3: δ_2	L2: δ_1 (m)	L3: δ_2	L2: δ_1 (m)	L3: δ_2
Nilai Sebenarnya (Truth)	2.100	0.050	5.500	0.050	10.650	0.050
Rata-rata (Mean)	2.084	0.049	5.500	0.050	10.636	0.050
Simpangan Baku (SSD)	0.026	0.002	0.022	0.001	0.013	0.001
Indeks Probabilitas (PI, L1)	–	1.000	–	1.000	–	1.000

Tabel 10.5: Pemetaan kerusakan dari FEM yang disederhanakan ke representasi fisik pada Abaqus FEM fidelitas tinggi.

FEM Tersimplifikasi					
$\delta_{1,true}$ (m)	$\delta_{2,true}$ (m)	$\Delta F_{,true}$ (m/N)	$\delta_{1,estimate}$ (m)	$\delta_{2,estimate}$ (m)	$\Delta F_{,estimate}$ (m/N)
2.100	0.0500	4.369e-12	2.084	0.0490	5.423e-11
10.650	0.0500	7.150e-11	10.636	0.0500	7.150e-11

Abaqus FEM DS ₁ : Semua Gelagar Rusak					
$\delta_{1,true}$ (m)	$\delta_{2,true}$ Mapped	$\Delta F_{,true}$ (m/N)	$\delta_{1,estimate}$ (m)	$\delta_{2,estimate}$ Mapped	$\Delta F_{,estimate}$ (m/N)
2.100	0.0009	4.393e-12	2.084	0.0009	4.102e-12
10.650	0.0009	7.150e-11	10.636	0.0009	7.150e-11


Abaqus FEM DS ₂ : Gelagar Interior Rusak					
$\delta_{1,true}$ (m)	$\delta_{2,true}$ Mapped	$\Delta F_{,true}$ (m/N)	$\delta_{1,estimate}$ (m)	$\delta_{2,estimate}$ Mapped	$\Delta F_{,estimate}$ (m/N)
2.100	0.0029	4.393e-12	2.084	0.0027	4.102e-12
10.650	0.0029	7.150e-11	10.636	0.0029	7.150e-11

Abaqus FEM DS ₃ : Gelagar Eksterior Rusak					
$\delta_{1,true}$ (m)	$\delta_{2,true}$ Mapped	$\Delta F_{,true}$ (m/N)	$\delta_{1,estimate}$ (m)	$\delta_{2,estimate}$ Mapped	$\Delta F_{,estimate}$ (m/N)
2.100	0.0031	4.393e-12	2.084	0.0029	4.102e-12
10.650	0.0031	7.150e-11	10.636	0.0031	7.150e-11

Catatan: Rasio retak fisik didasarkan pada rasio retak terhadap kedalaman balok penopang saja.

Pengaruh Derau


Dapat dilihat pada Tabel 10.6 dan Gambar 10.7 bahwa ketika SNR menurun (yaitu, derau sinyal meningkat), estimasi rata-rata untuk δ_1 menjauh dari nilai sebenarnya dan deviasi standar meningkat. Perhatikan bahwa ketika klasifikasi L1 di bawah 50%, estimasi rata-rata untuk δ_1 bergerak mendekati spesifikasi rata-rata sebelumnya, $\mu_1 = 10,65$ m; demikian pula, estimasi rata-rata untuk δ_2 bergerak mendekati spesifikasi rata-rata sebelumnya, $\mu_2 = 0$.



Gambar 10.6: Kurva fleksibilitas dari pemetaan $\delta_1 = 10,65$ untuk DS1 (δ_2 , estimasi dipetakan = 0,0009), DS2 (δ_2 , estimasi dipetakan = 0,0029), dan DS3 (δ_2 , estimasi dipetakan = 0,0031), masing-masing. Plot dari ketiga skenario menunjukkan kemampuan FEM Abaqus untuk secara akurat menangkap profil ΔF FEM yang disederhanakan dan ΔF puncak pada $\delta_1 = 10,65$ m.

Tabel 10.6: Hasil untuk klasifikasi kerusakan L1–L3 ketika $N = 1$, $V = 15,66$ m/s, dan SNR bervariasi antara 10 dan 20 dB.

Retak dengan SNR 20 dB				
	L2: δ_1 (m)	L3: δ_2 (m)	L2: δ_1 (m)	L3: δ_2 (m)
Nilai Sejati	2.100	0.050	10.650	0.050
Rata-rata	8.986	0.021	10.633	0.050
SSD	2.785	0.017	0.075	0.001
PI (L1)	–	0.459	–	1.000
Retak dengan SNR 10 dB				
	L2: δ_1 (m)	L3: δ_2 (m)	L2: δ_1 (m)	L3: δ_2 (m)
Nilai Sejati	2.100	0.050	10.650	0.050
Rata-rata	10.018	0.009	10.702	0.052
SSD	2.373	0.014	1.156	0.005
PI (L1)	–	0.099	–	1.000



Gambar 10.7 menampilkan distribusi densitas kernel bivariat yang dikembangkan berdasarkan estimasi δ_1 dan δ_2 . Estimasi ini diperoleh dari 100 set data dengan kondisi $\delta_1 = 10,65$ m dan $\delta_2 = 0,05$ pada keadaan sebenarnya, ketika jumlah pengujian $N = 1$, kecepatan kendaraan $V = 15,66$ m/s, serta nilai SNR masing-masing sebesar 30, 20, dan 10 dB.

Hasil visualisasi menunjukkan bahwa akurasi dan presisi klasifikasi kerusakan L2–L3 menurun seiring dengan penurunan SNR; dengan kata lain, semakin tinggi tingkat derau, semakin rendah akurasi klasifikasi. Dari Tabel 10.6, dapat diamati bahwa penurunan SNR memberikan dampak yang lebih besar terhadap akurasi klasifikasi kerusakan L1–L3 ketika retakan terjadi lebih dekat ke tumpuan dibandingkan jika retakan berada di tengah bentang. Misalnya, rasio retak sebesar 0,05 dapat dideteksi dengan akurasi tinggi di semua lokasi pada SNR = 30 dB, tetapi teknik estimasi Bayesian hanya mampu mendeteksi, menemukan, dan mengkuantifikasi retakan secara andal pada $\delta_1 = 10,65$ m ketika SNR = 10 dB.

Pengamatan ini semakin ditegaskan oleh hasil SSD (penyimpangan standar kuadrat) pada estimasi δ_1 , yang menunjukkan peningkatan nilai ketika retakan terjadi semakin dekat dengan tumpuan, khususnya pada pengujian dengan SNR = 20 dB dan SNR = 10 dB. Secara umum, SNR yang lebih rendah diyakini memberikan pengaruh yang lebih besar terhadap klasifikasi kerusakan di dekat tumpuan karena retakan dengan rasio $\delta_2 = 0,05$ hanya menimbulkan perubahan kecil pada fleksibilitas sistem. Perubahan kecil ini sulit terdeteksi pada tingkat kebisingan tinggi. Hal ini selaras dengan nilai ΔF yang tercatat pada Tabel 10.5, di mana perubahan nilai relatif lebih kecil ketika $\delta_1 = 2,1$ m.

Pengaruh Kuantitas Data Eksperimen

Untuk mengevaluasi dampak N terhadap klasifikasi kerusakan L1–L3, nilai $D_{m,phys,k}$ diperoleh dengan jumlah pengujian N yang sama, yaitu 5, 10, 15, dan 20 kali pengujian. Selanjutnya, diambil rata-rata multi-pengujian untuk setiap derajat kebebasan (*degree of freedom, DoF*) kendaraan. Dengan menggunakan rata-rata multi-pengujian, akar kuadrat rata-rata derau A_n dalam respons kendaraan berkurang. Hal ini secara efektif meningkatkan *Signal-to-Noise Ratio* (SNR) sehingga memungkinkan klasifikasi kerusakan yang lebih andal.

Berdasarkan Tabel 10.7, peningkatan jumlah pengujian kendaraan dalam rata-rata multi-pengujian memang menghasilkan peningkatan kinerja klasifikasi L1–L3. Secara khusus, pada kasus SNR = 10 dB, peningkatan jumlah pengujian N memberikan hasil signifikan. Klasifikasi L1 yang sebelumnya relatif rendah meningkat tajam, mencapai sekitar 90% ketika N = 20 kali pengujian. Akurasi dan presisi klasifikasi L2–L3 juga menunjukkan tren peningkatan seiring bertambahnya jumlah pengujian.

Selain itu, ketika posisi kerusakan δ_1 menjauh dari tumpuan, jumlah percobaan yang diperlukan untuk mencapai peningkatan serupa dalam akurasi dan presisi klasifikasi L1–L3 menjadi lebih sedikit. Hal ini terjadi karena perubahan yang disebabkan oleh kerusakan semakin nyata dalam respons dinamis jembatan, sehingga lebih mudah ditangkap dalam respons kendaraan. Dengan demikian, lebih sedikit percobaan yang diperlukan untuk menurunkan tingkat derau A_n hingga mencapai kondisi yang memungkinkan klasifikasi kerusakan yang andal.

Kesimpulan ini semakin diperkuat oleh hasil pada kasus $\delta_1 = 2,1$ m, di mana pada SNR = 20 dB lebih sedikit percobaan yang diperlukan untuk menghasilkan peningkatan klasifikasi dibandingkan dengan kasus SNR = 10 dB.

Tabel 10.7: Hasil klasifikasi kerusakan dari studi kuantitas data percobaan dengan variasi jumlah pengujian $N=5-20N = 5-20N=5-20$, kecepatan kendaraan $V=17,88 \text{ m/sV} = 17,88 \text{ m/sV}=17,88\text{m/s}$, dan $\text{SNR} = 10-20 \text{ dB}$.

10 dB SNR				
Jumlah Uji (N Runs)	15		20	
	L2: δ_1 (m)	L3: δ_2 (m)	L2: δ_1 (m)	L3: δ_2 (m)
Nilai Sejati	2.100	0.050	2.100	0.050
Rata-rata	6.084	0.034	4.688	0.041
SSD	3.226	0.016	3.204	0.013
PI (L1)	–	0.768	–	0.915
20 dB SNR				
Jumlah Uji (N Runs)	5		10	
	L2: δ_1 (m)	L3: δ_2 (m)	L2: δ_1 (m)	L3: δ_2 (m)
Nilai Sejati	2.100	0.050	2.100	0.050
Rata-rata	2.290	0.049	2.127	0.050
SSD	1.056	0.005	0.315	0.003
PI (L1)	–	0.998	–	1.000

Hal Tambahan yang Perlu Dipertimbangkan

Studi kecepatan harus dilakukan per jembatan untuk mengevaluasi dampak waktu hunian kendaraan di jembatan dan besarnya impuls dinamis terhadap klasifikasi kerusakan L1–L3 untuk sistem kendaraan-jembatan tertentu. Sebagai contoh, studi kecepatan dilakukan selama pengembangan teknik estimasi Bayesian untuk mendapatkan pemahaman yang lebih baik tentang bagaimana V memengaruhi klasifikasi kerusakan L1–L3 ketika terdapat tingkat kebisingan yang tinggi di berbagai lokasi kerusakan di sepanjang jembatan.

Hasil studi menunjukkan bahwa waktu hunian kendaraan di jembatan yang lebih lama (yaitu, kecepatan yang sedikit lebih rendah) lebih bermanfaat untuk klasifikasi kerusakan L1–L3 ketika kerusakan terjadi mendekati pertengahan bentang, sementara impuls dengan besaran yang lebih besar (yaitu, kecepatan yang sedikit lebih cepat) lebih bermanfaat untuk klasifikasi kerusakan L1–L3 ketika kerusakan terjadi lebih dekat ke tumpuan. Secara keseluruhan, temuan dari studi kecepatan menunjukkan adanya trade-off optimal antara besarnya eksitasi jembatan dan waktu hunian kendaraan-di-jembatan untuk δ_1 dan SNR tertentu.

Tidak seperti kebanyakan strategi pembaruan model yang menemukan perubahan kekakuan akibat kerusakan dengan meminimalkan fungsi objektif berdasarkan perbedaan antara properti modal terukur dan analitis, teknik estimasi Bayesian subjek mengidentifikasi kerusakan dengan menyetel FEM kendaraan-jembatan yang tertanam untuk meminimalkan perbedaan antara riwayat waktu akselerasi terukur dan terprediksi. Manfaat dari pemanfaatan data riwayat waktu secara langsung adalah tersedianya lebih banyak fitur respons untuk meningkatkan penyeterelan.

Namun, dengan menggunakan data riwayat waktu untuk pembaruan model, ketidakpastian model dari dampak lingkungan dan operasional perlu diidentifikasi untuk memungkinkan klasifikasi kerusakan yang andal. Selain itu, properti model kendaraan dan

jembatan harus akurat untuk menangkap dinamika sistem fisik dengan tepat. Teknik estimasi Bayesian berpotensi mengidentifikasi parameter jembatan, kendaraan, lingkungan, dan operasional yang tidak pasti secara bersamaan dengan parameter kerusakan yang tidak diketahui melalui kuantifikasi ketidakpastian.

Namun, perlu dicatat bahwa kuantifikasi ketidakpastian memiliki keterbatasannya sendiri yang perlu dipertimbangkan untuk mengklasifikasikan kerusakan secara andal dan efisien. Saat melakukan pembaruan model dengan data respons sistem nyata, serangkaian uji dinamis perlu dilakukan untuk menangkap respons riwayat waktu dalam kondisi operasi yang terkendali namun realistis. Memperoleh data dalam kondisi terkendali penting saat melakukan pembaruan langsung dengan data riwayat waktu, karena sumber eksitasi yang tidak diketahui, seperti yang diperkenalkan oleh lalu lintas acak, tidak dapat dengan mudah ditangkap dalam FEM dan akan memperkenalkan lebih banyak ketidakpastian model. Saat menyetel FEM dengan data eksperimen, sangat penting bahwa efek suhu sekitar, kekasaran permukaan, dan efek kerusakan retak nonlinier juga direpresentasikan secara akurat dalam model atau dimitigasi selama pengujian.

Suhu sekitar diketahui menyebabkan fluktuasi linier dan nonlinier yang signifikan dalam sifat modal jembatan yang dapat dengan mudah disalahartikan sebagai kerusakan. Efek suhu dapat dikurangi dengan melakukan pengujian pada waktu yang sama dan/atau pada suhu lingkungan yang hampir sama. Sebagai alternatif, sejumlah perangkat statistik dan analitis tersedia untuk memperhitungkan efek suhu dalam FEM. Kekasaran permukaan diketahui memperkuat interaksi dinamis antara kendaraan dan jembatan, dan jika tidak dimodelkan dengan tepat dapat menyebabkan kondisi buruk numerik. Profil permukaan jalan fisik berpotensi diperoleh untuk model numerik menggunakan instrumen khusus (misalnya, profilometer) untuk mengukur profil secara langsung selama pengujian fisik, atau dengan menghitung profil dari data akselerasi kendaraan eksperimental. Selain itu, setiap perbedaan antara profil yang diidentifikasi untuk FEM yang disederhanakan dan profil fisik berpotensi dapat diatasi melalui kuantifikasi ketidakpastian.

Efek retak nonlinier terjadi ketika pernapasan tereksitasi di dalam retakan, menyebabkan fluktuasi kekakuan dan redaman yang berkelanjutan sehingga menyulitkan identifikasi kerusakan. Efek retak nonlinier dapat ditangkap menggunakan pegas rotasi dengan kekakuan bilinear atau metode berbasis mekanika fraktur lainnya. Kebutuhan untuk memodelkan retak nonlinier dapat dikurangi jika data eksperimen diukur untuk tingkat eksitasi rendah di mana pernapasan tidak tereksitasi.

Penyertaan ketidakpastian yang disebutkan di atas, di samping ketidakpastian apa pun dalam massa kendaraan-jembatan, kekakuan, dan parameter redaman, dapat secara signifikan meningkatkan biaya komputasi teknik estimasi Bayesian dan menghasilkan waktu proses yang lebih tinggi. Salah satu pendekatan untuk mengurangi waktu proses adalah dengan melakukan analisis sensitivitas untuk mengidentifikasi dampak ketidakpastian parameter terhadap fluktuasi dalam data respons. Melalui pendekatan ini, parameter yang menunjukkan sedikit atau tidak ada pengaruh pada data respons dapat dipertahankan konstan dan dihapus dari ruang pembaruan model.

Faktor tambahan yang perlu dipertimbangkan ketika memperkirakan parameter yang tidak pasti adalah saling ketergantungan antara dua parameter (misalnya, hubungan kekakuan dan massa terhadap perubahan frekuensi) karena hal ini dapat menyebabkan masalah non-identifikasi. Kehati-hatian juga harus diambil dalam menentukan distribusi sebelumnya untuk mencerminkan sifat fisik setiap parameter. Jika pengetahuan tentang distribusi tidak tersedia, prior yang informatif lemah dapat ditentukan sehingga data yang diamati memberikan lebih banyak informasi kepada model. Terakhir, metrik validasi (misalnya, RMSE) perlu dimanfaatkan untuk mengidentifikasi seberapa baik model sesuai dengan respons sistem yang sebenarnya.

10.6 KESIMPULAN

Dalam bab ini, disajikan sebuah teknik estimasi Bayesian baru untuk klasifikasi kerusakan bertingkat yang dirancang untuk mengatasi keterbatasan strategi klasifikasi kerusakan lain dalam *Data-Based Health Monitoring (DBHM)*. Beberapa keterbatasan tersebut antara lain kebutuhan akan data berlabel, keharusan melakukan pengukuran pada kecepatan rendah, sensitivitas tinggi terhadap derau, serta kesulitan dalam mendeteksi kerusakan di sepanjang bentang jembatan.

Berbeda dengan sebagian besar teknik Bayesian yang ada, metodologi yang diusulkan menggunakan *Finite Element Model (FEM)* tertanam. Pendekatan ini tidak hanya mengurangi ruang parameter, tetapi juga membimbing model Bayesian melalui prinsip-prinsip berbasis fisika. Selain itu, berbeda pula dengan strategi pembaruan model konvensional yang biasanya mendeteksi perubahan kekakuan akibat kerusakan dengan meminimalkan perbedaan antara properti modal terukur dan analitis, teknik estimasi Bayesian ini mengidentifikasi kerusakan dengan menyetel FEM kendaraan–jembatan tertanam untuk meminimalkan perbedaan antara riwayat waktu akselerasi terukur dan terprediksi.

Pemanfaatan data riwayat waktu secara langsung memberikan sejumlah keuntungan, di antaranya:

1. Tersedianya lebih banyak fitur respons yang dapat meningkatkan ketelitian penyetelan model.
2. Kemudahan dalam mengidentifikasi sifat nonlinieritas.
3. Data riwayat waktu relatif kurang sensitif terhadap mode orde lebih tinggi dengan tingkat eksitasi rendah, yang biasanya sulit ditangkap secara akurat pada FEM yang disederhanakan.

Dalam memperbarui FEM tertanam dengan data riwayat waktu, penting untuk memperhitungkan ketidakpastian model akibat faktor lingkungan dan operasional, agar klasifikasi kerusakan tetap andal. Selain itu, properti model kendaraan dan jembatan harus cukup akurat untuk dapat merepresentasikan dinamika sistem fisik secara tepat. Melalui kerangka kerja Bayesian ini, berbagai perangkat komputasi dapat digunakan untuk memperbarui FEM dengan melakukan penyetelan terhadap data eksperimen. Hal ini tidak hanya memungkinkan klasifikasi kerusakan, tetapi juga identifikasi parameter model yang tidak pasti.

Kemampuan mengidentifikasi parameter model yang tidak pasti memiliki nilai penting ketika memantau struktur jembatan komposit, sebab adanya nonlinieritas material maupun geometri sering kali sulit diprediksi dan dimodelkan dengan akurat. Manfaat tambahan dari teknik ini adalah adanya metodologi pemetaan kerusakan yang mampu menghubungkan kerusakan yang teridentifikasi pada FEM jembatan tertanam dengan tingkat kerusakan yang lebih representatif secara fisik pada FEM jembatan dengan fidelitas lebih tinggi. Dengan cara ini, FEM kendaraan–jembatan yang lebih sederhana dan efisien secara komputasi dapat tetap digunakan dalam klasifikasi kerusakan, tanpa harus mengorbankan keakuratan interpretasi fisik terhadap besaran retakan.

Secara keseluruhan, teknik estimasi Bayesian ini terbukti menjanjikan untuk klasifikasi kerusakan serta kuantifikasi ketidakpastian dalam DBHM. Lebih jauh lagi, pendekatan ini berpotensi digunakan dalam evaluasi dampak kerusakan terhadap kinerja struktural, optimalisasi strategi pemeliharaan, serta perhitungan sisa umur pakai jembatan.

BAB 11

PEMBELAJARAN MESIN DAN DATA IOT DALAM ANALISIS KINERJA BETON

11.1 PENDAHULUAN

Perangkat *Internet of Things* (IoT) telah diadopsi secara luas dalam beberapa tahun terakhir untuk berbagai aplikasi industri, termasuk pemantauan beton. Perangkat/sensor tersebut memungkinkan pengumpulan data berharga dan kaya wawasan dari sumber yang sebelumnya belum dimanfaatkan. Dengan pertumbuhan penggunaan/adopsi sensor yang signifikan, dan selanjutnya pertumbuhan volume data yang dihasilkan secara signifikan, terdapat peluang signifikan dalam pengembangan algoritma yang mengandalkan data waktu nyata ini untuk menghasilkan wawasan bagi para praktisi.



Gambar 11.1: Sensor IoT yang tertanam pada beton digunakan untuk memantau suhu dan kekuatan in situ.

Untuk industri beton, sensor IoT biasanya digunakan untuk beberapa tujuan, di antaranya pemantauan suhu, kelembapan relatif, dan kekuatan (menggunakan metode kematangan) yang saat ini paling umum. Gambar 11.1 menunjukkan contoh sensor yang digunakan oleh praktisi beton untuk memantau sifat beton secara waktu nyata. Sensor dipasang pada tulangan beton dan tetap tertanam di dalam beton, tempat sensor memantau dan mencatat sifat beton. Sensor ini berkemampuan Bluetooth® sehingga praktisi dapat menggunakan ponsel modern apa pun untuk terhubung ke sensor dan mengekstrak data secara real-time.

Sebagai alternatif, pengguna dapat menggunakan gateway tetap yang mampu terhubung secara otomatis ke sensor tersebut dan mencadangkan data yang terkumpul. Dalam kedua kasus tersebut, data akan diunggah ke platform cloud yang dapat diakses oleh praktisi untuk melihat data yang terkumpul serta analitik dan wawasan yang dihasilkan.

Algoritma dan konsep yang disajikan dalam bab ini telah dilatih menggunakan data yang dikumpulkan dari puluhan ribu sensor serupa, yang digunakan di lebih dari 7.500 proyek yang mewakili wilayah geografis di lebih dari 45 negara dan mewakili ribuan campuran beton yang unik.

Algoritma pembelajaran mesin (ML)/kecerdasan buatan saat ini digunakan dalam beragam aplikasi. Kemajuan signifikan telah dicapai dalam dekade terakhir dalam penerapan algoritma ini di berbagai bidang seperti keuangan, kedokteran, pemasaran, ilmu material, optimasi proses, kendaraan otonom, pengenalan objek dan ucapan untuk pengembangan perangkat lunak, serta penyaringan konten pencarian web. Dengan kemajuan yang berkelanjutan di bidang ini, teknologi ini diharapkan akan segera merambah ke setiap bidang yang memungkinkan dan menjadi bagian dari kehidupan sehari-hari secara nyata. Meskipun terdapat kemajuan signifikan di bidang ML, hanya sedikit kemajuan yang dicapai (di luar penelitian akademis) dalam penerapan teknologi ini pada skala industri untuk industri beton.

Karena pengaruh berbagai faktor terhadap produksi dan kinerja beton, industri beton menghasilkan dan melacak data dalam jumlah yang signifikan. Data ini berkisar dari karakteristik bahan baku (misalnya, komposisi/kimia semen, gradasi agregat dan mineralogi, sifat dan dosis campuran kimia), kondisi sekitar (misalnya, kondisi cuaca pada saat penuangan), kondisi transit (misalnya, waktu dari pabrik ke lokasi), karakteristik kinerja (misalnya, kekuatan, slump, kadar udara, suhu beton segar, penyusutan), dan spesifikasi (misalnya, kadar bahan semen minimum, bahan semen tambahan maksimum, dll.).

Mempertimbangkan banyaknya data ini yang tersedia bagi praktisi dan peneliti beton, industri beton menyajikan peluang yang sangat baik untuk memanfaatkan algoritma mesin dalam berbagai aplikasi termasuk prediksi kinerja beton, deteksi anomali, formulasi campuran atau optimasi proses. Bab ini menyajikan bagaimana data sensor IoT yang tertanam dalam beton digunakan untuk melatih algoritma kecerdasan buatan untuk melakukan beberapa tugas yang membantu pengguna akhir sensor (produsen beton, kontraktor umum, dll.) dalam tugas sehari-hari.

11.2 ALGORITMA PEMBELAJARAN MESIN

Bentuk pembelajaran mesin yang paling banyak digunakan dalam penelitian ini disebut pembelajaran mesin terawasi. Dalam bentuk ini, algoritma 'dilatih' untuk melakukan tugas tertentu, seperti klasifikasi atau regresi, dengan memanfaatkan kumpulan data yang input dan outputnya dapat diakses oleh algoritma. Selama proses pelatihan ini, algoritma mengetahui fitur input yang diharapkan berkorelasi/memetakan output, dan juga mengetahui hasil output akhir yang diinginkan.

Output dan input dikorelasikan melalui fungsi nonlinier yang menggunakan parameter yang dapat disesuaikan secara arbitrer. Selama proses pelatihan algoritma, tujuannya adalah untuk menyesuaikan parameter-parameter ini agar mengkorelasikan fitur input dan output. Selama pelatihan, fungsi objektif (misalnya, persentase kesalahan absolut rata-rata, kesalahan absolut rata-rata, dll.) dihitung untuk menemukan kesalahan antara hasil output yang dihitung dan hasil yang diinginkan pada setiap iterasi. Algoritma memodifikasi parameter yang dapat

disesuaikan untuk mengurangi kesalahan ini ke batas yang dapat diterima dalam beberapa iterasi. Dalam beberapa sistem pembelajaran mesin, mungkin terdapat jutaan parameter yang dapat disesuaikan ini.

Untuk menyesuaikan parameter dengan tepat, algoritma pembelajaran menghitung "vektor gradien" yang menunjukkan seberapa besar kesalahan akan bertambah atau berkurang jika parameter ditambah atau dikurangi dengan jumlah tertentu. Dengan menggunakan vektor gradien, parameter kemudian disesuaikan untuk menyempurnakannya dan memperoleh kesesuaian yang lebih baik antara hasil yang diharapkan dan hasil keluaran. Banyak pilihan algoritma yang memanfaatkan konsep ini. Algoritma tersebut dapat mencakup, tetapi tidak terbatas pada, mesin vektor pendukung (SVM), regresi linier atau logistik, pohon keputusan, *k-nearest neighbor* (KNN), jaringan saraf tiruan (*multilayer perceptron*), dan jaringan saraf tiruan rekuren (RNN) atau algoritma memori jangka pendek panjang (LSTM).

Pengantar mendalam tentang konsep-konsep ini dapat ditemukan di berbagai literatur. Pemilihan algoritma biasanya ditentukan oleh tugas yang sedang dikerjakan. Misalnya, algoritma seperti RNN dan LSTM paling sering (tetapi tidak secara eksklusif) digunakan dalam mempelajari dependensi jangka panjang untuk masalah prediksi sekuens (misalnya, data temporal atau data bahasa alami), sementara model SVM atau KNN paling sering digunakan untuk masalah klasifikasi. Jaringan saraf tiruan diterapkan untuk masalah klasifikasi atau regresi, sementara jaringan saraf tiruan konvolusional, contoh khusus jaringan saraf tiruan, sebagian besar digunakan untuk masalah klasifikasi dan merupakan tulang punggung sebagian besar algoritma deteksi dan klasifikasi gambar modern.

Meskipun demikian, model-model ini dapat direkayasa untuk melakukan banyak tugas selain yang disebutkan berdasarkan akurasi, kompleksitas, kecepatan inferensi, sumber daya yang tersedia, dll. yang dibutuhkan. Terlepas dari algoritma atau metode yang dipilih, sebagian besar waktu dihabiskan dalam tiga area pengembangan yang berbeda (seringkali terkait): persiapan data/pemilihan fitur, penyetelan hiperparameter algoritma, dan evaluasi algoritma. Bab ini berfokus pada tantangan yang dihadapi di masing-masing area ini ketika data IoT terlibat. Langkah persiapan data biasanya mencakup alur pengumpulan data, pemformatan, pembersihan, deteksi anomali, dan pemilihan fitur. Meskipun semua tugas ini memiliki kepentingan yang signifikan, dalam kebanyakan kasus, pemilihan fitur merupakan aspek yang paling menantang. Performa algoritma sangat bergantung pada bagaimana persiapan data dilakukan, khususnya 'representasi' data yang disediakan.

Ketika algoritma dikembangkan untuk melakukan tugas tertentu, misalnya prediksi kekuatan beton, algoritma tersebut menggunakan 'fitur' yang mungkin mewakili karakteristik beton. Ini adalah informasi relevan yang dapat digunakan oleh pakar manusia atau algoritma untuk memprediksi kekuatan beton. Algoritma mempelajari (biasanya dari data historis) bagaimana setiap fitur yang diberikan berkaitan dengan kekuatan beton dan menggunakan informasi ini untuk memprediksi kinerja ketika dihadapkan dengan contoh baru. Setiap tugas yang akan diotomatisasi melalui algoritma (seperti memprediksi kekuatan) hanya dapat dilakukan jika fitur yang tepat dipilih. Misalnya, tidak dapat diklaim bahwa kekuatan beton dapat ditentukan hanya dengan menggunakan rasio air terhadap bahan semen dan kadar

semen. Sudah diketahui dengan baik bahwa banyak faktor lain yang dapat memengaruhi kinerja.

Di sisi lain, untuk sebagian besar aplikasi praktis, tidak semua faktor dapat dikumpulkan, atau data historis yang 'signifikan' mungkin tidak tersedia untuk setiap faktor tersebut. Selama tahap pemilihan fitur, tujuannya adalah untuk menentukan faktor-faktor yang akan memetakan sistem ke tingkat akurasi yang dapat diterima (ditentukan berdasarkan tugas yang sedang dikerjakan). Misalnya, jika 20 variabel dapat digunakan untuk memprediksi kekuatan beton dengan persentase kesalahan absolut rata-rata (MAPE) 15% dan 200 variabel dengan MAPE 7% ketika suatu algoritma dilatih pada volume data yang sama, praktisi perlu diwawancarai untuk menentukan kesalahan yang dapat diterima dan ketersediaan fitur tersebut dalam operasi sehari-hari mereka untuk menentukan tingkat kompleksitas yang dibutuhkan. Jelas bahwa kesalahan/ketidakpastian dalam masukan meningkat seiring dengan bertambahnya jumlah fitur masukan. Hal ini dapat menghasilkan model dengan jumlah masukan yang lebih besar (dan tingkat kesalahan yang secara teoritis lebih baik) yang memiliki akurasi keseluruhan yang lebih rendah dalam praktiknya.

Penyetelan hiperparameter sangat penting dalam pengembangan algoritma meskipun belum mendapat perhatian yang signifikan dalam literatur beton; dengan beberapa karya yang disajikan pada arsitektur model akhir yang dipilih dan bukan rentang hiperparameter yang diuji untuk mencapai arsitektur tersebut. Semua algoritma yang disebutkan menggabungkan banyak hiperparameter. Misalnya, jaringan saraf/perceptron multilayer akan memiliki hiperparameter berikut: jumlah lapisan, ukuran lapisan/jumlah neuron, laju pembelajaran (dan sering kali laju peluruhan), ukuran batch, metode dan laju regularisasi, momentum, metode optimasi yang digunakan/parameter pengoptimal, penggunaan putus/laju putus, fungsi aktivasi/fungsi kerugian, dll. Terlepas dari keahlian dan pengetahuan pengembang algoritma, hiperparameter ini harus ditentukan melalui coba-coba; apakah pencarian acak dilakukan atau metode lain seperti penurunan koordinat atau pencarian grid atau metode lanjutan lainnya seperti optimasi Bayesian atau algoritma genetika. Semua metode ini bergantung pada mencoba banyak kombinasi hiperparameter dan menentukan nilai 'ideal' untuk masalah yang dihadapi. Perhatikan bahwa perubahan signifikan dalam fitur input atau variabel output atau ukuran dataset sering kali memerlukan penentuan ulang hiperparameter.

Penting bahwa pencarian hiperparameter bersifat menyeluruh dan metode yang solid diimplementasikan untuk mengevaluasi satu set hiperparameter versus yang lain. Biasanya, pada tahap ini, dataset dibagi menjadi dataset pelatihan, pengujian, dan validasi. Dataset validasi digunakan untuk membandingkan satu set hiperparameter dengan yang lain. Ini adalah bagian data yang ditahan dari proses pelatihan model dan hanya digunakan untuk penyetelan hiperparameter (karena tidak bias terhadap kesesuaian model pada dataset pelatihan). Pilihan hiperparameter juga seringkali didasarkan pada kecepatan inferensi yang dibutuhkan model, bukan hanya akurasi. Misalnya, dalam kasus di mana inferensi model/prediksi mendekati waktu nyata yang cepat diperlukan, jaringan yang ringan mungkin lebih berguna daripada jaringan dengan waktu/kompleksitas komputasi yang jauh lebih tinggi namun berkinerja lebih baik dalam hal akurasi.

Penyetelan hiperparameter dan pemilihan fitur tidak sepenuhnya terpisah, tetapi biasanya bersifat iteratif. Dalam banyak kasus yang disajikan dalam bab ini, fitur masukan bertambah seiring perkembangan proyek dan pengumpulan data, atau seiring berkembangnya pengetahuan pengembang algoritma tentang permasalahan. Hal ini biasanya memerlukan pelatihan model berkelanjutan dan penyetelan hiperparameter. Terakhir, evaluasi algoritma tidak hanya dilakukan pada set evaluasi dan pengujian, tetapi juga bekerja sama dengan pengguna akhir algoritma. Hal ini dilakukan dengan mendemonstrasikan masukan dan keluaran algoritma kepada pakar dan praktisi di bidangnya untuk menilai pengalaman, akurasi, dan keandalan model. Hal ini khususnya penting untuk kasus-kasus seperti analisis dan optimasi kinerja konkret; karena terdapat perbedaan yang sangat besar dalam hal operasional, spesifikasi, badan pengatur, aplikasi, dan karakteristik bahan baku, tergantung pada aplikasi dan lokasi geografis.

Misalnya, jika set data pelatihan/validasi/uji diperoleh dari Amerika Utara dan Eropa, lalu digunakan untuk memprediksi kinerja di Asia, yang standar dan operasinya sangat berbeda (apalagi karakteristik materialnya), algoritmanya perlu dievaluasi secara terpisah dengan praktisi untuk menentukan kasus penggunaan, keandalan, kesesuaian, dll. Dalam kasus yang dikembangkan dalam penelitian ini, pengembangan mekanisme pengumpulan umpan balik pengguna dianggap penting untuk mengevaluasi kinerja model dan mengembangkannya lebih lanjut untuk kasus penggunaan tertentu. Misalnya, ketika saran algoritma ditampilkan kepada pengguna, pengguna dapat memasukkan tindakan untuk menentukan apakah mereka setuju dengan saran tersebut atau puas dengan hasil analitiknya. Misalnya, ketika prediksi kekuatan ditampilkan, algoritma selanjutnya mengumpulkan hasil penentuan kuat tekan laboratorium yang sebenarnya untuk mengevaluasi dirinya sendiri dan melakukan perbaikan menggunakan data tersebut. Data dan putaran umpan balik ini berperan penting dalam evolusi model-model ini.

Data dan Algoritma

Pada saat pengembangan model, sensor beton IoT, yang dikembangkan oleh Giatec Scientific dan digunakan dalam penelitian ini, telah digunakan di lebih dari 7.500 proyek di 45 negara. Data sensor ini mencakup data suhu, kematangan, kekuatan, dan kelembapan beton untuk ribuan campuran unik yang terdiri dari beragam bahan baku, dari berbagai sumber, terpapar berbagai kondisi lingkungan, digunakan untuk berbagai aplikasi, dan memanfaatkan praktik konstruksi yang berbeda.

Data ini dikumpulkan dari setiap sensor/proyek dalam basis data cloud terpusat yang dapat diakses oleh pengembang algoritma untuk keperluan pelatihan, pengembangan, validasi, dan pengujian algoritma. Seiring dengan pertumbuhan basis data ini yang pesat seiring dengan meningkatnya adopsi pemantauan beton IoT, Giatec telah mengembangkan algoritma, beberapa di antaranya disajikan dalam karya ini, yang memanfaatkan data ini untuk menyediakan alat bagi pengguna guna menganalisis campuran mereka, memprediksi kinerja di masa mendatang, mendeteksi anomali, mengoptimalkan campuran, dan sebagainya.

Algoritma pertama yang disajikan dalam karya ini dikembangkan untuk merekam waktu penguangan beton dari data suhu yang ditangkap oleh sensor beton IoT tertanam. Waktu

penuangan merupakan input penting bagi setiap sistem pemantauan kematangan beton. Kematangan merupakan pendekatan non-destruktif untuk menguji beton yang memungkinkan estimasi kuat tekan awal beton di tempat secara waktu nyata (real-time). Untuk memperkirakan kekuatan in situ, kalibrasi kekuatan-kematangan dilakukan melalui uji laboratorium pada campuran beton yang akan digunakan. Riwayat suhu beton dicatat secara in situ sejak beton dituang hingga saat estimasi kekuatan diinginkan. Riwayat suhu digunakan untuk menghitung indeks kematangan beton menggunakan, misalnya, metode Nurse-Saul atau metode usia ekuivalen. Dengan menggunakan indeks kematangan dan hubungan kekuatan-kematangan, kekuatan beton in situ dapat diperkirakan.

Karena indeks kematangan dihitung mulai dari saat beton dituang, estimasi waktu yang akurat sangat penting untuk perkiraan indeks kematangan dan selanjutnya kekuatannya yang tepat. Karena sensor pengukur suhu berukuran kecil dan tertanam dalam elemen beton besar, menentukan waktu kontak antara sensor dan beton menjadi cukup menantang untuk elemen yang kompleks atau besar. Pengguna sensor biasanya memasukkan perkiraan waktu seperti waktu kedatangan truk, awal penuangan, atau akhir penuangan. Pengguna jarang mencatat waktu pasti sensor tertutup beton. Tujuan dari penelitian ini adalah untuk mengembangkan model yang dapat secara akurat menyimpulkan waktu penuangan hanya berdasarkan data suhu.

Untuk melakukan hal ini, data historis dari lebih dari 20.000 sensor dikumpulkan dari basis data Giatec. Data waktu penuangan beton diberi label oleh pengguna sensor karena merupakan input yang diperlukan ke sistem. Data ini ditinjau oleh praktisi beton/pakar bidang terkait dengan tujuan menjawab dua pertanyaan: (1) apakah waktu penuangan dapat diketahui oleh pakar domain hanya berdasarkan data suhu, dan (2) jumlah rata-rata titik data, setelah penuangan, yang dibutuhkan oleh para pakar untuk mendeteksi penuangan beton. Gambar 11.2 adalah contoh data yang ditunjukkan kepada para pakar.

Para praktisi beton menemukan bahwa waktu penuangan dapat disimpulkan dari data suhu sensor melalui pengamatan kenaikan suhu beton yang disebabkan oleh sifat eksotermik hidrasi. Para ahli memiliki tingkat akurasi 95% dalam menentukan waktu penuangan ketika disajikan dengan data suhu-waktu secara keseluruhan. Akurasi ini umumnya menurun karena para ahli hanya disajikan dengan data beberapa jam (kurang dari 6 jam). Temuan bahwa para ahli domain mampu mendeteksi waktu penuangan ini dengan tingkat akurasi yang tinggi umumnya menunjukkan bahwa algoritma ML dapat digunakan untuk menemukan waktu ini secara mandiri melalui pelatihan algoritma pada data yang waktu ini diberi label dengan benar.


Data suhu yang dikumpulkan dari sensor dibersihkan menggunakan peninjauan data manual, serta menggunakan kriteria tertentu seperti menghapus sensor yang semua titik datanya berada dalam rentang di luar rentang umum penempatan beton, misalnya, jika semua suhu sepanjang waktu lebih rendah dari 0°C. Data sensor kemudian dibagi menjadi beberapa kasus dengan durasi pengukuran suhu yang berbeda, mulai dari 2 jam hingga 4 hari, sebelum pelatihan algoritma. Hal ini dilakukan untuk mengekspos algoritma ke data seperti yang terlihat dalam praktik di mana panjang data tidak dapat diprediksi dan bervariasi berdasarkan waktu pengguna mengambil data sensor menggunakan aplikasi seluler mereka.

Data dari 20.000 sensor dibagi menjadi dataset pelatihan, validasi, dan pengujian dengan pembagian masing-masing 60/20/20. Rata-rata, setiap sensor memiliki data suhu selama 20 hari. Data dari setiap sensor dipotong menjadi beberapa jendela dengan panjang bervariasi, berkisar antara 2 jam hingga 4 hari, menghasilkan lebih dari 500.000 jendela dengan panjang bervariasi (dengan jumlah titik data suhu yang bervariasi) yang digunakan untuk pelatihan algoritma.

Beberapa model dilatih menggunakan data tersebut, termasuk jaringan saraf tiruan, jaringan saraf tiruan konvolusional, dan LSTM. Input untuk semua model ini adalah data suhu satu dimensi. Empat metrik digunakan untuk mengevaluasi dan membandingkan model: kesalahan absolut rata-rata (dalam jam) yang dihitung antara waktu penguangan yang dipilih pengguna dan waktu penguangan yang diprediksi oleh model; persentase keberhasilan dalam menemukan waktu penguangan (untuk dibandingkan dengan pakar domain); periode waktu (setelah penguangan) yang diperlukan model untuk memprediksi kejadian penguangan; dan terakhir, waktu/kecepatan inferensi algoritma.

Untuk setiap model, penyetelan hiperparameter dilakukan. Hal ini penting dalam menentukan variabel-variabel termasuk jumlah lapisan jaringan saraf tiruan, ukuran lapisan, laju pembelajaran, fungsi aktivasi, jumlah lapisan konvolusional, jumlah filter, ukuran filter, Norma Batch, tingkat putus, dll. Berdasarkan pekerjaan penyetelan hiperparameter awal, jaringan saraf tiruan konvolusional dipilih. Jenis jaringan ini sangat umum untuk aplikasi pengenalan gambar, klasifikasi gambar, dan deret waktu keuangan karena dihipotesiskan mampu menangkap dependensi spasial dan temporal melalui penerapan filter konvolusional.


Jaringan ini sering digunakan ketika invariansi translasi diinginkan, seperti dalam permasalahan yang mirip dengan waktu penguangan; di mana jaringan diharuskan untuk memprediksi waktu penguangan dengan tepat terlepas dari titik waktu terjadinya (yaitu, apakah itu terjadi pada awal sinyal suhu-waktu atau hari-hari setelah pemantauan suhu). Jaringan ini memanfaatkan lapisan konvolusi bertumpuk yang diikuti oleh lapisan perseptron multilapis. Jumlah dan ukuran filter untuk bagian konvolusi serta ukuran dan jumlah lapisan untuk perseptron multilapis ditentukan melalui hasil penyetelan hiperparameter. Jaringan menggunakan konsep putus-putus dan normalisasi batch. Keluaran jaringan adalah titik waktu terjadinya penguangan. Model yang dikembangkan memiliki tingkat keberhasilan 90% dalam menemukan waktu penguangan untuk sensor dengan waktu berlabel, yang cukup mendekati keberhasilan para pakar domain.




Gambar 11.2: Contoh data suhu-waktu yang menunjukkan waktu penuangan beton.

Rata-rata kesalahan absolut adalah 3,2 jam. Rata-rata, model mampu mendeteksi waktu penuangan yang tepat setelah 6 jam titik data setelah peristiwa penuangan. Hal ini umumnya disebabkan oleh kenaikan panas yang signifikan (akibat hidrasi) yang terjadi setelah periode waktu tersebut. Terakhir, model memiliki waktu inferensi 200–500 ms (tergantung pada panjang data suhu-waktu) saat diterapkan. Hal ini dianggap dapat diterima untuk pengalaman pengguna mengingat model tersebut dijalankan di latar belakang tanpa mengganggu penggunaan aplikasi seluler.


Beberapa contoh prediksi ditunjukkan pada Gambar 11.3, 11.4, dan 11.5. Garis vertikal biru menunjukkan prediksi algoritma, sementara garis merah menunjukkan pilihan pengguna. Gambar 11.3 menunjukkan kasus-kasus di mana pengguna hanya mengandalkan algoritma untuk memprediksi waktu penuangan. Gambar 11.4 menunjukkan contoh kasus di mana algoritma mengoreksi pilihan waktu penuangan yang salah oleh pengguna, dan Gambar 11.5 menunjukkan contoh kasus di mana pengguna dan algoritma mencapai kesepakatan dalam waktu kurang dari 2 jam. Dalam kasus kesepakatan tersebut, pengguna tidak diberitahu untuk mengubah waktu penuangan, mengingat perbedaan kecil dalam indeks kematangan (kekuatan berkorelasi dengan logaritma indeks).



Gambar 11.3: Contoh waktu penuangan yang terdeteksi di mana pengguna mengandalkan saran algoritma (biru).



Gambar 11.4: Contoh waktu penuangan yang terdeteksi di mana deteksi (biru) memiliki akurasi yang lebih tinggi daripada pilihan pengguna (merah).



Gambar 11.5: Contoh waktu penuangan yang terdeteksi di mana deteksi (biru) berada dalam rentang 2 jam dari pilihan pengguna (merah).

Untuk lebih mendukung pelanggan selama proses penerapan kematangan untuk pemantauan kekuatan in situ, diperlukan pengembangan algoritma yang memungkinkan ketidakakuratan dalam kalibrasi kematangan dapat dideteksi dan dilaporkan kepada pengguna. Meskipun kematangan merupakan konsep yang cukup dipahami di pasar Amerika Utara dan Eropa, dengan standar ASTM (American Society for Testing and Materials), CSA (Safety Standards in Canada), dan EN (Eropa) yang telah mapan, konsep ini relatif baru untuk wilayah lain di dunia.

Hal ini membutuhkan dukungan yang signifikan dari pemasok sensor kematangan dalam mendukung pelanggan selama pengembangan kalibrasi kematangan dan penggunaannya di lapangan. Oleh karena itu, model di mana ketidakakuratan tersebut dapat ditemukan secara mandiri dapat memberikan nilai yang signifikan bagi praktisi yang menggunakan konsep tersebut untuk pertama kalinya dan memberikan pemasok sistem pemantauan peningkatan efisiensi dalam dukungan pelanggan.

Untuk mengembangkan algoritma ini, data campuran dikumpulkan dari basis data cloud Giatec dan dari data historis QA/QC dari 10 produsen lain di seluruh AS, Kanada, dan Eropa. Data ini terakumulasi menjadi lebih dari 7.500 campuran unik dan lebih dari 300.000 titik data kuat tekan dari catatan historis QA/QC yang mencakup 5–15 tahun riwayat, bergantung pada produsennya. Data tersebut mewakili berbagai proporsi campuran, yang digunakan untuk berbagai aplikasi, memanfaatkan beragam bahan baku (material semen,

manajemen rantai pasokan (SCM), berbagai campuran tambahan, karakteristik agregat, dll.) dan terpapar pada berbagai kondisi lingkungan dan praktik konstruksi.

Data kinerja mewakili tiket dari lebih dari 20.000 proyek. Data tersebut mencakup material semen (semen Portland dan SCM) dari 300 sumber, lebih dari 200 campuran kimia yang tersedia secara komersial, dan mencakup agregat yang mewakili setiap gradasi dalam ASTM C33 dari lebih dari 40 sumber yang berbeda. Banyak tantangan yang terkait dengan pra-pemrosesan dan persiapan data tersebut.

Pemilihan fitur input dan deteksi outlier merupakan tugas yang paling menantang secara teknis dan paling berperan dalam keberhasilan model. Pemilihan fitur input didasarkan pada dua kriteria: (1) ketersediaan data untuk fitur tersebut dan (2) pentingnya fitur tersebut dalam memprediksi kinerja beton. Fitur yang tersedia dibagi menjadi dua kategori, yaitu fitur yang paling tersedia (misalnya, proporsi campuran, jenis semen, gradasi agregat, kondisi lingkungan, metode perawatan, dosis admixture, dll.) dan fitur yang paling tidak tersedia (misalnya, informasi kimia/sertifikasi pabrik bahan semen dan SCM, bentuk agregat dan mineralogi, suhu air pencampur, waktu transit, dll.).

Fitur-fitur ini dikumpulkan dan disajikan kepada beberapa pakar domain untuk menentukan kepentingan relatifnya. Fitur yang paling penting dan paling tersedia dalam data digunakan untuk pelatihan model awal. Fitur yang dipilih untuk pelatihan model diperluas secara bertahap dalam beberapa putaran sambil mengevaluasi pengaruh peningkatan fitur input terhadap MAPE dan mean absolute error (MAE).

Metode seleksi fitur statistik lainnya digunakan, termasuk metode filter dan metode wrapper. Hal ini diharapkan tidak hanya untuk memprediksi kinerja laboratorium beton yang digunakan dalam pengembangan kalibrasi kematangan, tetapi juga kriteria kinerja lain untuk beton lapangan (misalnya, slump) untuk modul lain yang dikembangkan dalam platform Giatec. Oleh karena itu, banyak variabel yang mungkin tidak memiliki korelasi kuat dengan kekuatan tetap dimasukkan dalam kumpulan data untuk model tersebut.

Untuk meningkatkan kualitas data, model deteksi outlier dikembangkan. Model ini memanfaatkan model pembelajaran tanpa pengawasan. Detektor outlier tanpa pengawasan tersebut biasanya merupakan model klasifikasi. Dua model digunakan dan dibandingkan untuk tujuan ini: hutan isolasi dan faktor outlier lokal. Model-model tersebut dievaluasi dengan membandingkan outlier dan inlier yang terdeteksi dalam data dengan yang diberi label outlier dan inlier oleh pakar domain. Skor f1 dihitung berdasarkan skor ini dan model faktor outlier lokal dipilih karena mengungguli model hutan isolasi. Model ini tidak hanya digunakan untuk meningkatkan kualitas dataset tetapi juga digunakan sebagai modul deteksi anomali dalam platform Giatec.


Setelah deteksi outlier, beberapa model regresi dilatih pada data ini dengan tujuan memprediksi kalibrasi kematangan campuran tertentu menggunakan pengetahuan tentang proporsi campuran. Model-model ini mencakup, tetapi tidak terbatas pada, jaringan saraf tiruan, regresi vektor pendukung, regresi proses Gaussian, pohon keputusan, regresi logistik, regresi ridge, dan regresi laso. Setelah pengujian awal untuk model-model ini, jaringan saraf tiruan (multilayer perceptron) dipilih untuk masalah ini.

Seperti halnya masalah deteksi waktu penuangan, dataset dibagi menjadi set pelatihan, validasi, dan pengujian, dengan pembagian 60/20/20. Dipastikan bahwa campuran yang ada dalam set pelatihan tidak ada di set lain. Misalnya, jika titik data untuk campuran tertentu yang diuji pada usia tertentu ada dalam set pelatihan, semua usia pengujian atau contoh pengujian lainnya untuk campuran yang sama ditambahkan ke set pelatihan. Hal ini dilakukan untuk mencegah jaringan mendapatkan wawasan tentang semua campuran dan bahan baku. Penyetelan hiperparameter dilakukan untuk menentukan jumlah lapisan, ukuran lapisan, fungsi aktivasi, metode normalisasi, laju pembelajaran, metode regularisasi dan parameter, laju putus, penggunaan normalisasi batch, dll.

Hiperparameter dipilih berdasarkan minimisasi MAPE dan MAE. Jaringan saraf tiruan yang dioptimalkan menggunakan konsep normalisasi batch, putus, normalisasi L2, dan menggunakan fungsi aktivasi unit linier terektifikasi (ReLU). Ukuran spesifik jaringan (dalam hal jumlah lapisan dan ukuran lapisan) tidak dijelaskan di sini karena banyak ukuran jaringan yang berbeda ditemukan memadai dan memberikan akurasi yang serupa setelah penyetelan hiperparameter (misalnya, laju pembelajaran, fungsi aktivasi, laju putus, dll.) dilakukan.

Algoritma yang diterapkan mencapai MAPE sebesar 13,8% dan MAE sebesar 720 PSI (pound per inci persegi) pada prediksi kekuatan ketika dievaluasi pada set pengujian (rata-rata semua sumber data). Metrik ini umumnya berubah berdasarkan usia pengujian konkret, dengan kesalahan terendah pada 28 hari. Hal ini disebabkan oleh ketersediaan data yang lebih tinggi pada hari ke-28 dan pengaruh yang lebih rendah dari kondisi penyembuhan/kondisi lingkungan pada kekuatan hari ke-28 jika dibandingkan dengan kekuatan hari ke-1.

Perlu disebutkan bahwa setelah pengembangan dan rilis model, pekerjaan pemilihan/pengembangan fitur terus berlanjut seiring perkembangan model, semakin banyak keluaran yang diminta oleh pengguna akhir, dan semakin banyak tren yang terlihat. Misalnya, model awalnya tidak mempertimbangkan penggunaan pozolan alami atau pengisi batu kapur. Namun, tren industri yang terus berkembang (seperti penggunaan semen batu kapur Portland) mengharuskan pengumpulan data terkait material tersebut. Hal ini memerlukan pembaruan yang konsisten pada basis data, alur data, karakteristik model, dan selanjutnya hiperparameter. Untuk menggunakan model guna mendeteksi ketidakakuratan dalam kalibrasi kematangan, sebuah modul dikembangkan pada platform cloud Giatec (Giatec360TM).



Gambar 11.6: Representasi skematis potensi optimasi berdasarkan kekuatan target.

Modul ini membandingkan kalibrasi campuran yang dimasukkan pengguna (perkembangan kekuatan dari waktu ke waktu/kematangan berdasarkan proporsi campuran yang dimasukkan) dengan prediksi model, dan deviasi yang besar ditandai sebagai ketidakakuratan oleh pengguna. Campuran dapat ditandai memiliki kekuatan yang sangat tinggi atau sangat rendah. Ketidakakuratan lain dalam suhu datum, energi aktivasi, suhu referensi, dll., juga dapat ditandai menggunakan metode ini.

Lebih lanjut, solusi terbalik jaringan dilakukan untuk menentukan potensi reduksi semen dan optimasi campuran. Ketika kalibrasi kekuatan-kematangan dilakukan dan dimasukkan ke dalam sistem, kalibrasi tersebut diverifikasi menggunakan metode yang disebutkan. Selanjutnya, untuk campuran yang lolos verifikasi ini, kekuatan yang ditentukan/target, yang dimasukkan oleh pengguna, dibandingkan dengan kinerja campuran, dengan mempertimbangkan faktor keamanan yang dipilih pengguna.

Hal ini ditunjukkan secara skematis pada Gambar 11.6. Ketika kinerja campuran melebihi kekuatan target, kapasitas reduksi material semen ditentukan dengan menyapu input semen dan SCM dari jaringan (sambil mempertahankan yield) hingga kekuatan campuran memenuhi kekuatan target. Hal ini menghasilkan saran kapasitas reduksi material semen. Fitur ini saat ini digunakan oleh ratusan pengguna setiap bulan dengan potensi reduksi semen rata-rata yang disarankan sebesar 10%. Sebagaimana telah disebutkan sebelumnya, algoritma ini dilatih berdasarkan data historis tidak hanya kekuatan, tetapi juga karakteristik termasuk slump, laju alir slump, kadar udara, suhu pengiriman, kenaikan panas in situ dan suhu maksimum, penyusutan, serta prediksi uji koefisien difusi/permeabilitas klorida cepat. Algoritma lengkap dengan kemampuan ini telah diterapkan agar pengguna dapat melakukan prediksi kinerja campuran secara menyeluruh, bergantung pada proporsi campuran, komposisi dan karakteristik bahan baku, serta kondisi lingkungan.


Lebih penting lagi, algoritma ini dapat digunakan untuk tujuan optimasi/perubahan campuran, di mana pengguna dapat menentukan informasi tentang spesifikasi berbasis kinerja mereka, seperti kekuatan yang ditentukan, slump, atau kadar udara; spesifikasi preskriptif, seperti kadar bahan semen minimum, dan penggantian SCM maksimum; serta kondisi sekitar dan lingkungan, seperti suhu, kelembapan, lokasi penuangan, dll.

Algoritma optimasi telah dirancang khusus untuk memungkinkan penentuan proporsi campuran yang dioptimalkan agar memenuhi kriteria kinerja ini, sekaligus meminimalkan biaya, jejak karbon, atau gabungan metrik biaya dan jejak karbon. Hal ini menghasilkan campuran yang terus berubah berdasarkan spesifikasi yang berubah atau kondisi sekitar, memastikan bahwa optimasi terus tercapai terlepas dari faktor-faktor lain yang memengaruhi. Algoritma tersebut juga memanfaatkan data sensor IoT yang dikumpulkan secara terus-menerus untuk memastikan bahwa optimasi dan tingkat kinerja tercapai. Algoritma ini telah digunakan dalam uji coba dengan satu produsen mitra, dengan tujuan untuk mengurangi jejak karbon dari dua campuran yang umum digunakan, dengan kekuatan desain nominal 25 dan 35 MPa. Campuran tersebut memiliki spesifikasi yang dibutuhkan untuk slump dan kadar udara 100–150 mm dan kadar udara 5–8% serta persyaratan preskriptif untuk penggantian terak maksimum sebesar 30%.

Algoritma ini mampu menyesuaikan campuran tersebut untuk meminimalkan kadar bahan semen dan meningkatkan penggantian terak serta penggunaan bahan tambahan pengurang air dengan rentang tinggi. Meskipun campuran tersebut tidak disajikan di sini karena dianggap hak milik oleh produsen, jejak karbon ditunjukkan untuk menunjukkan dampak penggunaan algoritma. Untuk membandingkan campuran yang disarankan dengan bisnis produsen seperti biasa, serta komposisi yang banyak digunakan dalam literatur, metode oleh Damineli dkk. (2010) digunakan. Penulis mengusulkan indeks yang mengkorelasikan jumlah bahan pengikat yang dibutuhkan untuk mengembangkan satu unit sifat beton (yaitu, kuat tekan). Indeks intensitas bahan pengikat (bi) yang ditunjukkan pada Persamaan (11.1) berikut mengkuantifikasi ekoefisiensi campuran beton,

$$bi = \frac{b}{p} \tag{11.1}$$

dengan b adalah total konsumsi bahan pengikat (kg/m^3) dan p adalah persyaratan kinerja (yaitu, kuat tekan dalam MPa). Gambar 11.7 menunjukkan intensitas pengikat campuran ini dibandingkan dengan bisnis produsen campuran siap pakai seperti biasa serta ribuan campuran yang dirangkum dalam Damineli dkk. (2010). Terlihat jelas bahwa campuran yang disarankan oleh algoritma memiliki intensitas pengikat yang jauh lebih rendah untuk kekuatan yang sebanding jika dibandingkan dengan data literatur atau data produsen. Perhatikan bahwa kekuatan untuk semua campuran ini lebih tinggi daripada nilai kekuatan nominalnya, yaitu 25 dan 35 MPa.



Gambar 11.7: Hubungan antara intensitas bahan pengikat dan kuat tekan 28 hari dari catatan internasional yang diadaptasi dari.

11.3 KESIMPULAN

Sebagaimana ditunjukkan oleh kasus-kasus yang disajikan, industri beton menghadirkan peluang yang sangat baik untuk memanfaatkan algoritma pembelajaran mesin (ML) dalam menganalisis kinerja beton, berkat banyaknya data yang tersedia dan pertumbuhan penggunaan sensor IoT. Kasus-kasus yang disajikan dalam karya ini menunjukkan bagaimana data ini dapat digunakan untuk mengembangkan algoritma yang dapat memberikan nilai signifikan bagi para praktisi beton.

Kasus pertama yang disajikan menunjukkan bagaimana data IoT yang dikumpulkan dari sensor beton tertanam digunakan untuk mengembangkan algoritma yang dapat menyimpulkan waktu penuangan beton hanya dengan menggunakan data suhu. Model ini ditemukan memiliki akurasi deteksi sebesar 90% dan memprediksi waktu penuangan yang rata-rata berada dalam rentang 3 jam dari waktu yang dipilih pengguna. Kasus kedua menunjukkan pengembangan algoritma yang dapat memverifikasi kalibrasi kekuatan-kematangan yang dikembangkan di laboratorium beton serta menyarankan potensi penghematan semen bagi para praktisi beton dengan membandingkan kinerja saat ini dengan kekuatan yang ditentukan/ditargetkan. Model ini memiliki skor MAPE sebesar 13,8% dan secara umum menunjukkan potensi penghematan semen hingga lebih dari 10%. Algoritma ini juga telah diterapkan untuk tujuan prediksi kinerja dan optimasi campuran, serta diujicobakan dengan produsen beton siap pakai yang menunjukkan peningkatan jejak karbon yang dihasilkan dengan penggunaan model ini.

BAB 12

PEMBELAJARAN MENDALAM STRUKTUR NONLINIER

12.1 PENDAHULUAN

Estimasi respons struktur nonlinier yang akurat di atas tingkat beban desain sangat penting untuk memastikan keselamatan struktur dan infrastruktur sipil. Untuk analisis statistik kinerja struktur dalam berbagai bahaya, efisiensi estimasi respons struktural sangat penting. Meskipun metode elemen hingga fidelitas tinggi dapat memberikan estimasi respons struktural nonlinier yang akurat, metode ini membutuhkan komputasi yang mahal dan waktu yang lama, terutama ketika beberapa sampel respons diperlukan untuk analisis statistik.

Untuk meningkatkan efisiensi estimasi respons nonlinier, pemodelan orde tereduksi berbasis fisika telah banyak diimplementasikan. Misalnya, model elemen hingga orde tereduksi, yang menggunakan model elemen hingga yang lebih sederhana untuk menangkap perilaku model kompleks asli, telah berhasil digunakan untuk estimasi respons struktur nonlinier yang efisien. Pendekatan linearisasi statistik, di mana sistem nonlinier direpresentasikan oleh sistem linier ekuivalen, juga telah digunakan untuk estimasi respons nonlinier yang efisien. Meskipun model orde tereduksi berbasis fisika telah berkinerja baik dalam tugas estimasi respons nonlinier, umumnya merupakan metode khusus yang memerlukan perancangan yang cermat. Lebih lanjut, perhatian besar perlu diberikan pada identifikasi parameter model yang sesuai dari data numerik dan/atau eksperimen.

Dibandingkan dengan pemodelan orde tereduksi berbasis fisika, pemodelan orde tereduksi berbasis data dapat dianggap sebagai metode umum untuk meningkatkan efisiensi estimasi respons struktural nonlinier. Dengan pesatnya pertumbuhan daya komputasi, terutama komputasi heterogen, pemodelan orde tereduksi berbasis data telah menunjukkan potensi besar untuk simulasi sistem kompleks yang efisien.

Dengan keunggulan spektrum aplikasinya yang luas, jaringan saraf tiruan (JST) telah menjadi metode paling populer untuk pemodelan tereduksi berbasis data. Pendekatan pemodelan berbasis jaringan saraf dalam (JST) telah banyak digunakan di berbagai bidang, seperti pemrosesan bahasa alami, pengenalan suara, kompresi dan restorasi citra, serta self-driving. Dalam JST feedforward, masukan diproses secara berurutan oleh beberapa lapisan neuron untuk menghasilkan keluaran.

Dengan bertambahnya jumlah lapisan, kemampuan pemodelan JST meningkat pesat. Dengan demikian, JST dengan lebih dari dua lapisan tersembunyi telah banyak digunakan. Selain itu, arsitektur jaringan baru, seperti jaringan saraf tiruan konvolusional (CNN), jaringan dekonvolusional (DeConvNet), jaringan saraf tiruan rekuren (RNN), dan jaringan saraf tiruan residual (ResNet) juga telah diusulkan untuk meningkatkan kemampuan pemodelan JST umpan maju secara signifikan untuk berbagai tugas.

ANN juga telah banyak digunakan untuk analisis keselamatan struktur dan infrastruktur sipil. Misalnya, jaringan umpan maju telah digunakan untuk estimasi respons dan identifikasi

parameter sistem derajat kebebasan tunggal (SDOF) dan multiderajat kebebasan (MDOF). Dengan kemampuan mendeteksi fitur-fitur penting secara otomatis, CNN juga telah banyak digunakan untuk estimasi respons sistem struktural.

Keberhasilan penerapan ANN biasanya bergantung pada data pelatihan berkualitas tinggi dalam jumlah besar, terutama untuk jaringan saraf dalam. Misalnya, keberhasilan penerapan CNN untuk klasifikasi citra sangat bergantung pada pengembangan kumpulan data citra yang besar. Namun, set data eksitasi-respons berkualitas tinggi biasanya tidak tersedia atau mahal untuk diperoleh untuk struktur dan infrastruktur sipil, yang membatasi penerapan pembelajaran mendalam. Untuk tujuan ini, diusulkan metodologi pembelajaran mendalam yang ditingkatkan pengetahuan (KEDL), yang menggunakan pengetahuan sebelumnya untuk memandu proses pelatihan.

Secara khusus, rumus berbasis fisik dan empiris ditambahkan ke fungsi kerugian untuk memanfaatkan mekanisme penurunan gradien. Sebenarnya, gagasan untuk menggunakan pengetahuan sebelumnya untuk meningkatkan efisiensi pelatihan jaringan telah diusulkan selama beberapa dekade. Metode ini mengintegrasikan persamaan pengatur fisik ke dalam fungsi kerugian untuk melatih jaringan penyelesaian persamaan diferensial parsial (PDE) secara efisien. Selain pengetahuan domain berbasis persamaan, pengetahuan domain bebas persamaan baru-baru ini telah diintegrasikan ke dalam pengoptimal bentuk berbasis pembelajaran penguatan mendalam untuk mitigasi aerodinamis yang efisien pada struktur yang sensitif terhadap angin. Dalam studi ini, metodologi KEDL berbasis persamaan digunakan untuk pelatihan jaringan estimasi respons yang efisien data.

Respons struktural pada setiap langkah waktu pada dasarnya ditentukan oleh respons langkah waktu sebelumnya dan eksitasi langkah waktu saat ini. Dengan demikian, respons langkah waktu terakhir dan eksitasi langkah waktu saat ini perlu dipertimbangkan dalam jaringan estimasi respons. Dalam sudut pandang ini, RNN, dengan kemampuan untuk secara berulang meneruskan keluaran langkah terakhir ke masukan saat ini, sangat cocok untuk tugas estimasi respons. RNN telah berhasil digunakan untuk estimasi respons sistem nonlinier.

Dalam studi ini, neuron memori jangka pendek panjang (LSTM) digunakan untuk estimasi respons struktural. Secara khusus, arsitektur LSTM bertumpuk digunakan untuk mempelajari hubungan eksitasi-respons. Proyeksi domain wavelet diperkenalkan untuk meningkatkan efisiensi pelatihan dengan menyederhanakan hubungan masukan-keluaran jaringan. Kinerja estimasi respons berbasis jaringan saraf tiruan diperiksa secara komprehensif dengan respons struktural nonlinier yang diinduksi angin.


12.2 JARINGAN SARAF TIRUAN DALAM

JST merupakan komposisi operasi aritmatika sederhana yang direpresentasikan oleh neuron. Karena data mengalir secara berurutan melalui neuron dalam suatu jaringan, neuron dapat dikategorikan ke dalam beberapa lapisan sesuai dengan posisinya dalam jaringan. Dalam sudut pandang ini, JST terdiri dari lapisan masukan, lapisan tersembunyi, dan lapisan keluaran. Gambar 12.1 menggambarkan struktur jaringan saraf tiruan umpan maju 3 lapis. Lapisan masukan menerima data, lapisan tersembunyi memproses data, dan lapisan keluaran

menghasilkan hasilnya. Setiap neuron dalam lapisan tersembunyi dan lapisan keluaran melakukan operasi pada masukan x_i sebagai:

$$y = \sigma \left(\sum_i w_i x_i + b \right) \quad (12.1)$$

di mana y adalah keluaran neuron; $\sigma(\cdot)$ adalah fungsi aktivasi nonlinier; w_i adalah bobot yang sesuai dengan masukan x_i ; dan b adalah bias neuron.



Gambar 12.1: Skema ANN umpan-maju 3 lapis.

Dari sudut pandang hubungan masukan-keluaran, ANN dapat diperlakukan sebagai aproksimator fungsi umum. Dengan menyesuaikan bobot dan bias setiap neuron, hubungan masukan-keluaran dapat disesuaikan. Selisih antara keluaran jaringan dan target yang sesuai dikuantifikasi oleh fungsi kerugian, yang dapat berupa metrik jarak, distribusi probabilitas, dan entropi. Dengan data pelatihan, proses pelatihan jaringan pada dasarnya meminimalkan fungsi kerugian. Metodologi pelatihan yang paling berhasil adalah propagasi-balik, di mana parameter jaringan saraf tiruan setiap lapis diperbarui melalui penurunan gradien.

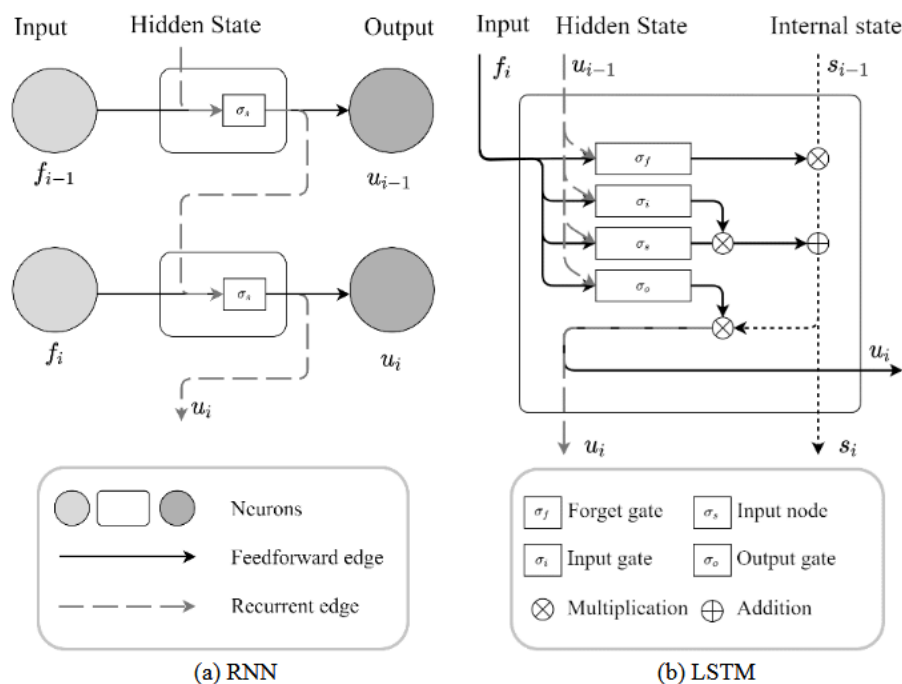
RNN

Dibandingkan dengan jaringan saraf tiruan umpan-maju konvensional (Gambar 12.1), neuron dalam RNN memiliki status tersembunyi untuk mengingat data masa lalu dan secara berulang meneruskan status tersembunyi tersebut ke masukan langkah berikutnya. Gambar 12.2a menunjukkan aliran data RNN neuron tunggal yang dibentangkan dalam langkah waktu $i - 1$ dan i . Pada setiap langkah waktu, neuron menerima data dari masukan (tepi umpan maju) dan status tersembunyi dari langkah waktu terakhir (tepi berulang).

Dengan status tersembunyi, keluaran pada waktu i terkait dengan masukan pada waktu i dan keluaran sebelumnya. Dengan demikian, arsitektur RNN sangat cocok untuk 'mengingat'

keluaran sebelumnya (LeCun dan rekan-rekan., 2015). Dengan kemampuan mengingat keluaran sebelumnya, RNN telah banyak diterapkan pada tugas-tugas terkait data sekuens, termasuk pemrosesan bahasa alami, pengenalan ucapan, dan klasifikasi audio.

Arsitektur RNN sangat cocok untuk estimasi respons struktural. Secara khusus, untuk dinamika struktural, respons saat ini (yaitu, perpindahan u , kecepatan \dot{u} , dan percepatan \ddot{u}) ditentukan oleh status struktural langkah waktu terakhir (u_{i-1} , \dot{u}_{i-1} , \ddot{u}_{i-1}) dan eksitasi langkah waktu saat ini f_i . Dengan demikian, baik status struktur langkah waktu terakhir (keluaran pada waktu $i - 1$) maupun eksitasi saat ini (masukan pada waktu i) perlu dipertimbangkan untuk memperkirakan respons struktural secara akurat, yang tentu saja sesuai dengan keunggulan RNN (Gambar 12.2a).



Gambar 12.2: Skema aliran data dalam RNN dan LSTM.

LSTM

Meskipun status tersembunyi menangkap keluaran sebelumnya, RNN hanya dapat secara efektif meneruskan informasi dalam rentang waktu yang sangat terbatas karena masalah gradien yang menghilang dan meledak. Neuron LSTM yang ditunjukkan pada Gambar 12.2b diusulkan untuk mengatasi masalah ini. Dibandingkan dengan RNN yang ditunjukkan pada Gambar 12.2a, LSTM memiliki status internal untuk menyimpan informasi lebih lama dan serangkaian gerbang untuk mengontrol bagaimana masukan memengaruhi status internal, status tersembunyi, dan keluaran.

Secara spesifik, gerbang lupa belajar untuk membersihkan isi status internal; simpul internal dan gerbang masukan memutuskan bagaimana status internal diperbarui; Gerbang keluaran dan keadaan internal s_i bersama-sama menentukan u_i keluaran. Dengan gerbang ini,

neuron LSTM dapat menghindari masalah gradien yang menghilang dan meledak untuk deret waktu panjang dan secara efektif memodelkan dinamika struktural nonlinier.

Metodologi KEDL

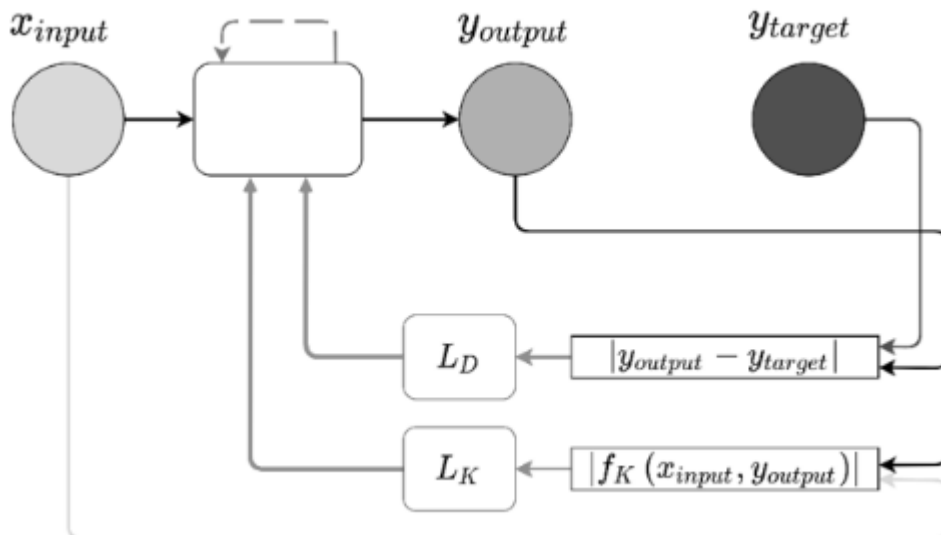
Dalam DL konvensional, sejumlah besar data pelatihan sangat penting untuk melatih dan memvalidasi ANN secara efektif. Kesulitan dalam memperoleh data pelatihan berkualitas tinggi merupakan salah satu tantangan utama yang membatasi penerapan DL pada permasalahan rekayasa. Untuk dinamika struktural, biasanya sangat mahal untuk mengukur respons dinamika struktural.

Selain itu, data pengukuran pasti terkontaminasi oleh derau akibat lingkungan yang keras. Untuk tujuan ini, Snaiki dan Wu (2019) mengusulkan metodologi KEDL, di mana pengetahuan awal tentang sistem target diintegrasikan ke dalam fungsi kerugian untuk memandu proses pelatihan dengan lebih baik dan meningkatkan ketahanan derau. Dalam KEDL, fungsi kerugian L dihitung sebagai:

$$L = (1 - a)L_D + aL_K \tag{12.2}$$

di mana L_D adalah fungsi sub-kerugian berbasis data; L_K adalah fungsi sub-kerugian berbasis pengetahuan; a adalah parameter yang menentukan pentingnya setiap fungsi sub-kerugian terhadap proses pelatihan. Jika a ditetapkan ke nol, KEDL setara dengan proses pelatihan berbasis data konvensional.

Gambar 12.3 menggambarkan penerapan KEDL pada RNN sederhana. Pembaruan bobot neuron dipandu oleh dua fungsi kerugian, yaitu, kehilangan data L_D dan kehilangan pengetahuan L_K . Kehilangan data L_D adalah metrik yang mengkuantifikasi perbedaan antara keluaran jaringan saraf y_{output} dan keluaran target y_{target} yang diberikan oleh data pelatihan. Kehilangan pengetahuan adalah metrik yang mengkuantifikasi perbedaan antara keluaran jaringan saraf y_{output} dan keluaran berbasis pengetahuan $f_K(x_{input}, y_{output})$, di mana $f_K(\cdot)$ adalah relasi masukan-keluaran yang dijelaskan oleh pengetahuan sebelumnya.



Gambar 12.3: Skema KEDL yang diterapkan pada RNN sederhana.

Dalam studi ini, fungsi sub-rugi pengetahuan L_K ditentukan oleh persamaan berbasis fisika dan informasi empiris sebagai berikut:

$$L_K = f_{LK}(L_p, L_E) \quad (12.3)$$

di mana $f_{LK}(\cdot)$ adalah fungsi kombinasi L_p dan L_E ; L_p mengkuantifikasi deviasi hubungan masukan-keluaran jaringan dari persamaan pengatur berbasis fisika; dan L_E mengkuantifikasi deviasi dari informasi empiris. Dalam KEDL, set data pelatihan, persamaan berbasis fisika, dan informasi empiris digunakan bersama untuk memandu proses pelatihan dengan meminimalkan fungsi kerugian. Perlu dicatat bahwa pentingnya L_p dan L_E terhadap proses pelatihan disesuaikan dengan fungsi kombinasi $f_{LK}(\cdot)$.

Proyeksi Domain Wavelet

Format dan fitur masukan dan keluaran menentukan kompleksitas JST, dan karenanya kesulitan pelatihan. Dengan demikian, fitur yang diekstraksi secara manual telah digunakan secara luas sebagai masukan jaringan untuk menyederhanakan hubungan masukan-keluaran dan mencapai efisiensi pelatihan yang tinggi.

Untuk estimasi respons struktural berbasis jaringan saraf, proses pelatihan dapat memakan waktu dan menghadirkan masalah konvergensi jika riwayat eksitasi dan respons digunakan secara langsung sebagai masukan dan keluaran jaringan. Untuk dinamika struktur dan infrastruktur sipil, struktur tersebut terutama tereksitasi dalam rentang frekuensi tertentu dan tidak sensitif terhadap eksitasi di luar rentang ini.

Dengan demikian, hubungan eksitasi-respons dapat disederhanakan dengan menguraikannya dalam domain frekuensi. Wavelet, yang dirancang dengan cermat dengan sifat penopang kompak dan ortogonal, memiliki keuntungan dalam menguraikan sinyal nonstasioner dalam domain frekuensi. Dalam studi ini, hubungan eksitasi-respons diidentifikasi dalam domain wavelet untuk mengurangi kompleksitas masukan dan keluaran, sehingga mempercepat proses pelatihan. Secara spesifik, aturan pemetaan antara koefisien wavelet respons struktural dan gaya eksternal (misalnya, eksitasi angin) ditangkap oleh arsitektur LSTM bertumpuk dengan metodologi KEDL.

Dalam proyeksi domain wavelet, respons $u(t)$, $\dot{u}(t)$, $\ddot{u}(t)$, dan gaya eksternal $f(t)$ dapat didekati sebagai:

$$u(t) \approx \sum_{\tau} W_{u,j,\tau} \phi_{j,\tau}(t) \quad (12.4)$$

$$\dot{u}(t) \approx \sum_{\tau} W_{u,j,\tau} \dot{\phi}_{j,\tau}(t) \quad (12.5)$$

$$\ddot{u}(t) \approx \sum_{\tau} W_{u,j,\tau} \ddot{\phi}_{j,\tau}(t) \quad (12.6)$$

$$f(t) \approx \sum_{\tau} W_{f,j,\tau} \varphi_{j,\tau}(t) \quad (12.7)$$

dengan W adalah koefisien wavelet; j adalah skala wavelet; $\varphi_{j,\tau}(t) = \varphi_j(t - \tau)$ adalah fungsi skala wavelet; t adalah waktu kontinu; dan τ adalah parameter pergeseran wavelet. Berdasarkan Persamaan (12.4) – (12.7), persamaan kesetimbangan dinamis dalam domain waktu [yaitu, $m\ddot{u}(i) + c\dot{u}(i) + ku(i) = f(t)$, dengan m, c , dan k masing-masing adalah massa, koefisien redaman, dan kekakuan] dapat dinyatakan dalam domain wavelet sebagai:

$$m \sum_{\tau} W_{u,j,\tau} \Gamma_{j,k,l}^{2,0} + c \sum_{\tau} W_{u,j,\tau} \Gamma_{j,k,l}^{1,0} + k \sum_{\tau} W_{u,j,\tau} \delta_{\tau,l} = \sum_{\tau} W_{f,j,\tau} \delta_{\tau,l} \quad (12.8)$$

di mana $\delta_{\tau,l}$ merupakan representasi dari delta Kronecker; $\Gamma_{j,\tau,l}^{1,0}$ dan merupakan koefisien koneksi $\Gamma_{j,\tau,l}^{2,0}$ yang dinyatakan sebagai:

$$\Gamma_{j,\tau,l}^{1,0} = \int \dot{\phi}_{j,\tau}(t) \varphi_{j,l}(t) dt \quad (12.9)$$

$$\Gamma_{j,\tau,l}^{2,0} = \int \phi_{j,\tau}(t) \varphi_{j,l}(t) dt \quad (12.10)$$


Dibandingkan dengan estimasi respons domain waktu, estimasi respons domain wavelet memiliki keunggulan berupa kalkulasi turunan bebas kesalahan, yang krusial bagi KEDL karena kehilangan pengetahuan (L_K) merupakan fungsi dari kecepatan dan percepatan dinamis. Dalam domain waktu, kesalahan kecepatan dan percepatan akibat diferensiasi numerik dapat menyebabkan masalah akurasi yang serius dan karenanya memengaruhi pelatihan jaringan. Di sisi lain, wavelet dapat dirancang dengan turunan analitis dengan orde yang diperlukan. Dengan demikian, turunan perpindahan bebas kesalahan tersedia dalam domain wavelet dan dapat digunakan untuk memfasilitasi proses pelatihan KEDL. Fungsi wavelet Daubechies dengan orde n dapat didiferensiasikan n kali. Dalam studi ini, fungsi wavelet Daubechies dengan orde 10 digunakan.

12.3 VERIFIKASI KINERJA

Kinerja KEDL diverifikasi pada bagian ini dengan sistem SDOF linier yang merepresentasikan menara bandara. JST dilatih dan diuji dalam berbagai skenario untuk melakukan penilaian komprehensif terhadap kinerja KEDL dalam hal akurasi estimasi, efisiensi data, dan ketahanan terhadap derau. Sistem SDOF linier digunakan sebagai tolok ukur untuk verifikasi kinerja karena kesederhanaannya. Untuk jaringan saraf tiruan yang dikonfigurasi dengan tepat dan pelatihan yang memadai (dalam hal nilai fungsi rugi yang rendah), penggunaan sistem dinamis struktural linier atau nonlinier pada dasarnya tidak memengaruhi verifikasi kinerja KEDL.

Konfigurasi Sistem SDOF yang Digunakan untuk Verifikasi

Gambar 12.4 secara skematis menunjukkan sistem SDOF yang digunakan untuk verifikasi kinerja. Diasumsikan bahwa sistem SDOF dieksitasi oleh beban angin $f(t)$ dan memiliki gaya redaman $f_D(t)$ dan gaya pemulih $f_R(t)$.



Gambar 12.4: Konfigurasi skema sistem SDOF.

Parameter sistem SDOF disusun berdasarkan pengukuran lapangan menara bandara. Secara spesifik, massa m , koefisien redaman c , dan kekakuan k masing-masing ditetapkan sebagai $3,237 \times 10^6 \text{ kg}$, $1,515 \times 10^4 \text{ N} \cdot \text{m/s}$, dan $1,773 \times 10^5 \text{ Nm/s}$. Karena kurangnya pasangan pengukuran beban angin dan respons struktural berkualitas tinggi, beban angin hasil sintesis dan respons terkait yang dihitung dengan metode Runge-Kutta orde ke-4 (RK4) digunakan sebagai set data pelatihan dalam studi ini.

Kecepatan angin terdiri dari komponen rata-rata \bar{s} dan komponen fluktuasi $\bar{s}(t)$ sebagai:

$$s(t) = \bar{s} + \bar{s}(t) \quad (12.11)$$


di mana $\bar{s} = 36,4 \text{ m/s}$ adalah kecepatan angin rata-rata pada ketinggian 46,6 m; $\bar{s}(t)$ disintesis menggunakan pendekatan representasi spektral dengan spektrum tipe Karman:

$$\frac{nS_{\bar{s}}(n)}{\sigma_{\bar{s}}^2} = \frac{4 \left[\frac{nL_s}{\bar{s}} \right]}{\left\{ 1 + 70.8 \left[\frac{nL_s}{\bar{s}} \right] \right\}^{\frac{5}{6}}} \quad (12.12)$$

di mana n mewakili frekuensi; $S_{\bar{s}}(n)$ adalah kerapatan spektral daya target (PSD); $\sigma_{\bar{s}}$ adalah deviasi standar fluktuasi; L_s adalah skala panjang integral turbulensi yang ditetapkan sebesar 80 m (Huang dan rekan-rekan., 2013). Beban angin diperoleh dari simulasi kecepatan angin $s(t)$ menggunakan teori kuasi-stabil:

$$f(t) = \frac{1}{2} \rho A C_D s^2(t) \quad (12.13)$$

di mana ρ adalah densitas udara yang ditetapkan sebesar $1,25\text{kg/m}^3$; A adalah luas ekuivalen yang ditetapkan sebesar 840m^2 ; koefisien hambatan C_D ditetapkan sebesar 1,2. Sampel respons dihasilkan dengan metode RK4 dengan perpindahan dan kecepatan awal nol. Frekuensi pengambilan sampel adalah 50 Hz. Dua durasi (16 detik dan 600 detik) dipilih untuk tujuan verifikasi yang berbeda. Gambar 12.5 menggambarkan eksitasi dan respons yang sesuai dari satu sampel dalam data pelatihan. Sementara eksitasi stasioner, modulasi amplitudo yang jelas diamati dalam respons.



Gambar 12.5: Eksitasi dan respons sistem SDOF linear.

Modulasi amplitudo pada dasarnya dihasilkan dari fakta bahwa respons struktural dari suatu saat waktu tertentu bergantung pada eksitasi dari saat waktu sebelumnya. Perlu dicatat bahwa jaringan yang dilatih dengan data pelatihan yang dihasilkan secara numerik hanya dapat menangkap hubungan input-output yang tertanam dalam simulasi, yang mungkin menyimpang dari sistem bandara-menara yang sebenarnya.

Untuk menangkap hubungan eksitasi-respons sistem bandara-menara secara realistis, jaringan saraf tiruan perlu dilatih dengan pengukuran berkualitas tinggi. Dalam studi ini, kami bertujuan untuk mengeksplorasi penerapan KEDL pada estimasi respons struktural, alih-alih verifikasi realisme estimasi berbasis jaringan. Oleh karena itu, penggunaan simulasi numerik dianggap cukup untuk tujuan verifikasi di sini.

Arsitektur LSTM Bertumpuk

Berbagai arsitektur RNN dalam telah diusulkan untuk berbagai tujuan. Dalam studi ini, lapisan LSTM bertumpuk disarangkan dengan lapisan padat untuk estimasi respons dinamis nonlinier (Gambar 12.6). Ketiga lapisan LSTM digunakan untuk menyimpan status struktur dan mengakomodasi pemetaan nonlinier antara dataset masukan dan keluaran. Lapisan padat terakhir ditambahkan untuk mengonversi keluaran lapisan LSTM menjadi koefisien wavelet respons struktural. Setiap lapisan LSTM memiliki delapan neuron LSTM, dan lapisan padat memiliki satu neuron dengan fungsi aktivasi unit linier terrektifikasi (ReLU). Jumlah neuron

pada lapisan padat dipilih agar sesuai dengan keluaran sistem SDOF. Baik eksitasi maupun respons dinormalisasi dengan cara berikut:

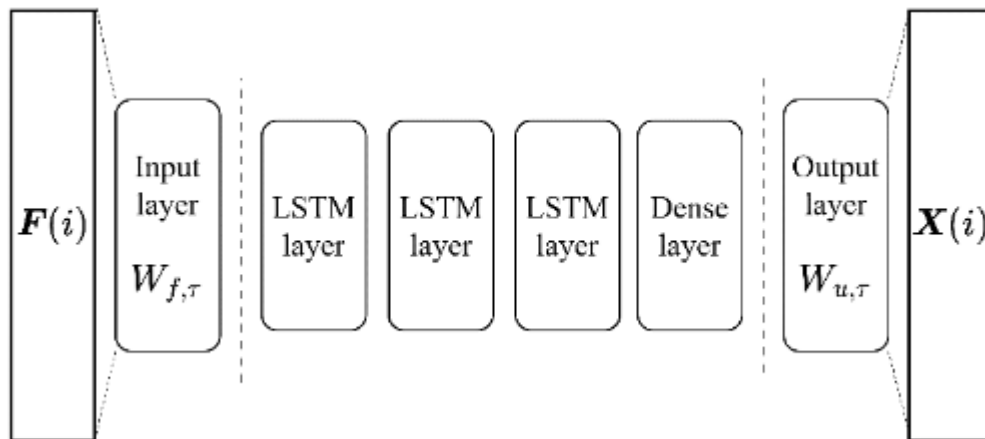
$$f_N(i) = \frac{f(i)}{E(|f|_{max})} \quad (12.14)$$

Dan

$$u_N(i) = \frac{u(i)}{E(|u_{maks}|)} \quad (12.15)$$

di mana $f_N(i)$ dan $u_N(i)$ masing-masing adalah respons dan eksitasi ternormalisasi; $E(|u|_{maks})$ dan $E(|f|_{maks})$ adalah estimasi maksimum yang diharapkan dari sampel yang tersedia; dan i adalah waktu diskrit. Masukan jaringan ditetapkan sebagai koefisien wavelet eksitasi ternormalisasi $W_{f,\tau}$ dengan bentuk B dikalikan 1, di mana B adalah jumlah koefisien wavelet. Keluaran jaringan adalah koefisien wavelet respons ternormalisasi dengan bentuk yang sama yaitu $W_{f,\tau}$.

Model jaringan saraf tiruan disiapkan dan dilatih dengan platform pembelajaran mesin TensorFlow yang banyak digunakan (Abadi dan rekan-rekan., 2016).



Gambar 12.6: Arsitektur jaringan LSTM bertumpuk.

Skema optimasi AdaMax digunakan dengan laju pembelajaran adaptif (Kingma dan Ba, 2014). Fungsi sub-kerugian berbasis data dan berbasis pengetahuan masing-masing dihitung sebagai:

$$L_D = \frac{1}{N_D} \sum_{k=1}^{N_D} \left[\sum_{\tau} (W_{out,k,u,j,\tau} - W_{tar,k,u,j,\tau})^2 \right] \quad (12.16)$$

Dan

$$\sum_{k=1}^{N_k} \left[m \sum_{\tau} W_{out,k,u,j,\tau} \Gamma_{j,\tau,l}^{2,0} + c \sum_{\tau} W_{out,k,u,j,\tau} \Gamma_{j,\tau,l}^{1,0} + k \sum_{\tau} W_{out,k,u,j,\tau} \delta_{\tau,l} - \sum_{\tau} W_{f,j,\tau} \delta_{\tau,l} \right]^2 \quad (12.17)$$


di mana N_D dan N_K masing-masing adalah sampel yang digunakan untuk menghitung fungsi sub-kerugian berbasis data dan berbasis pengetahuan; W_{out} dan W_{tar} masing-masing adalah koefisien wavelet keluaran dan target. Nilai a dari Persamaan (12.2) ditetapkan sebesar 0,5 dalam studi ini. Perlu dicatat bahwa pengaruh L_K dan L_D pada proses pelatihan dapat dimodifikasi dengan menggunakan nilai a lain pada Persamaan (12.2). Jaringan saraf dianggap cukup terlatih jika fungsi kerugian berhenti menurun.

Performa Metodologi KEDL


Akurasi Estimasi

Akurasi KEDL yang telah dilatih pertama kali diverifikasi dengan sistem SDOF yang disajikan pada Gambar 12.4. Seratus sampel 16 detik (800 langkah waktu) digunakan untuk proses pelatihan. Sebanyak 800 sampel lainnya digunakan sebagai dataset uji. Tingkat dekomposisi wavelet ditetapkan sebesar 4 untuk mencakup 99% energi dalam respons struktural. Gambar 12.7a menyajikan perbandingan antara respons berbasis RK4 dan keluaran jaringan saraf tiruan yang telah dilatih. Sampel yang disajikan pada Gambar 12.7 dipilih secara acak dari dataset uji.

Nilai galat absolut estimasi berbasis jaringan juga ditunjukkan pada Gambar 12.7a dengan menggunakan respons berbasis RK4 sebagai referensi. KEDL yang telah dilatih berkinerja baik dengan galat maksimum 0,0172 dan galat rata-rata 0,0045. Respons terperinci antara 10 detik dan 12 detik disajikan pada Gambar 12.7b untuk menyelidiki hubungan antara nilai galat dan respons. Dapat ditemukan bahwa galat mencapai maksimum lokalnya ketika respons mencapai nilai puncak lokalnya (misalnya, 10,32 detik dan 11,02 detik), yang menunjukkan bahwa jaringan saraf tiruan mungkin lebih sulit mengidentifikasi respons puncak lokal dibandingkan dengan respons non-puncak.

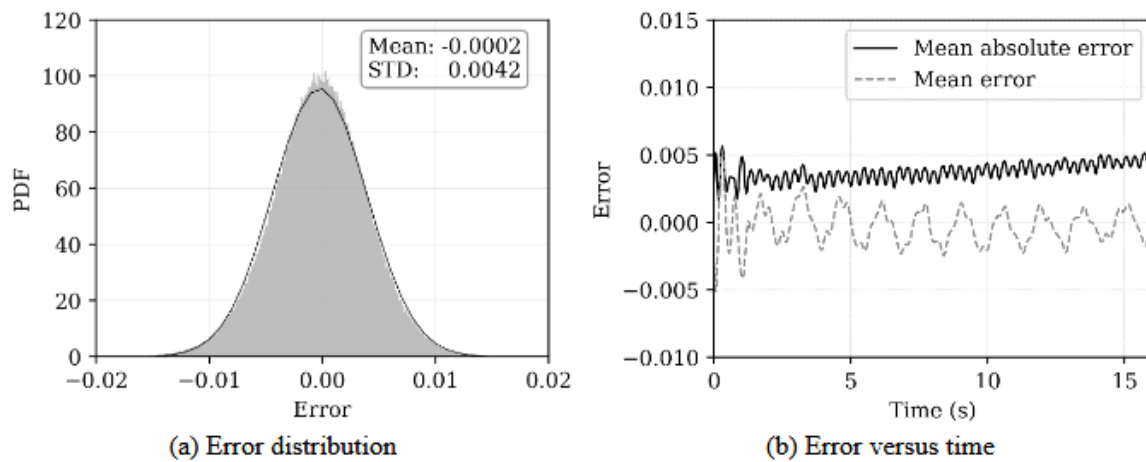


(a) Normalized response with 16-s duration



(b) Normalized response between 10 and 12s

Gambar 12.7: Estimasi respons berbasis jaringan terpilih.



Gambar 12.8: Statistik kesalahan estimasi respons berbasis jaringan.


Statistik galat estimasi berbasis jaringan diperoleh dari 800 sampel uji dan disajikan pada Gambar 12.8a. Rata-rata dan simpangan baku galat masing-masing adalah -0,0002 dan 0,0042. Distribusi Gaussian yang sesuai juga ditunjukkan pada Gambar 12.8a sebagai garis hitam pekat. Dibandingkan dengan distribusi Gaussian, galat lebih terkonsentrasi di sekitar nol.

Untuk tugas estimasi respons struktural, akumulasi galat sangat penting. Oleh karena itu, selain distribusi probabilitas galat umum, penting untuk mengeksplorasi perkembangan galat terhadap waktu. Nilai kesalahan rata-rata dan kesalahan absolut rata-rata dihitung dan disajikan pada Gambar 12.8b. Dapat diamati bahwa kesalahan estimasi sedikit meningkat seiring waktu. Ketergantungan waktu dapat dikaitkan dengan fakta bahwa neuron LSTM secara berulang menggunakan keluaran langkah waktu terakhir untuk menghitung keluaran langkah waktu saat ini dan mengakumulasi kesalahan estimasi. Perlu dicatat bahwa akumulasi kesalahan dapat dikurangi dalam aplikasi dunia nyata hanya dengan melatih jaringan saraf tiruan dengan sampel yang lebih panjang.

Efisiensi Data

Salah satu keunggulan metodologi KEDL adalah efisiensi datanya. Secara spesifik, pengetahuan berbasis fisika dan/atau empiris digunakan untuk memberikan panduan bagi proses pelatihan dan mengurangi kebutuhan akan set data pelatihan. Dibandingkan dengan proses pelatihan berbasis data konvensional, jumlah set data pelatihan yang relatif lebih sedikit diperlukan untuk mencapai tingkat akurasi yang sama.

Untuk menyoroti keunggulan efisiensi data KEDL dibandingkan metodologi pelatihan berbasis data konvensional, jaringan yang ditunjukkan pada Gambar 12.6 dilatih dengan dua nilai a pada Pers. (12.2), yaitu $a = 0,5$ dan $a = 0$. Ketika $a = 0,5$, fungsi kerugian berbasis data dan berbasis pengetahuan digunakan untuk memandu proses pelatihan. Ketika $a = 0$, hanya fungsi kerugian berbasis data yang digunakan untuk memandu proses pelatihan. Untuk setiap nilai a , jumlah sampel bervariasi dari 1 hingga 10. Karena setiap sampel berisi 800 langkah waktu diskrit, ukuran set data pelatihan bervariasi dari 800 hingga 8.000.



Gambar 12.9: Kesalahan versus ukuran dataset untuk dua nilai a .

Pelatihan untuk kedua nilai a dihentikan ketika fungsi kerugian berhenti menurun dan dengan demikian dapat dianggap memadai. Nilai kesalahan absolut rata-rata diplot terhadap ukuran dataset pelatihan pada Gambar 12.9 yang menunjukkan bahwa kesalahan pelatihan berbasis data konvensional konvergen ketika ukuran dataset melebihi 5.600.

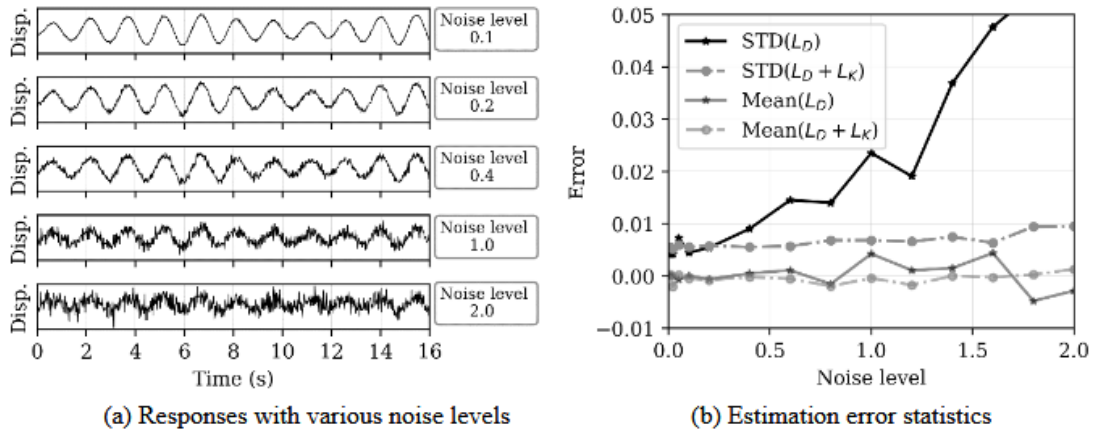
Sebaliknya, kesalahan KEDL konvergen dengan ukuran 3.200. Perbedaan antara kedua metodologi pelatihan menunjukkan bahwa fungsi sub-kerugian berbasis pengetahuan L_K meningkatkan mekanisme regularisasi selama proses pelatihan. Juga diamati bahwa, bahkan jika ukuran dataset tidak mencukupi untuk konvergensi (yaitu, ukuran dataset lebih kecil dari 2400), kesalahan KEDL jauh lebih rendah daripada kesalahan pelatihan berbasis data konvensional, yang semakin membuktikan efisiensi data yang diberikan oleh fungsi kerugian berbasis pengetahuan.

Ketahanan Derau

Untuk aplikasi nyata estimasi respons struktural berbasis jaringan saraf tiruan, ketahanan terhadap derau sangat penting. Pada bagian ini, ketahanan derau KEDL dinilai dengan menambahkan berbagai tingkat derau ke respons dalam set data pelatihan. Derau Gaussian putih digunakan untuk mengemulasi kontaminasi derau dalam pengukuran. Tingkat derau dikuantifikasi sebagai rasio deviasi baku derau terhadap sinyal respons. Variasi dari 0,1 hingga 2 diadopsi (Gambar 12.10a) yang menunjukkan bahwa derau tidak dapat diamati secara visual ketika tingkatnya di bawah 0,2. Ketika tingkat mencapai 2,0, respons asli tidak dapat diidentifikasi dengan mudah.

Jaringan saraf tiruan dilatih dengan $\alpha = 0,5$ dan $\alpha = 0$, yaitu, metodologi pelatihan berbasis data konvensional yang ditingkatkan pengetahuannya. Gambar 12.10b menggambarkan deviasi standar dan nilai rata-rata galat terhadap tingkat derau. Untuk $\alpha = 0$, galat meningkat cepat seiring dengan meningkatnya tingkat derau. Di sisi lain, untuk $\alpha = 0,5$, galat hanya meningkat sedikit seiring dengan meningkatnya tingkat derau. Bahkan

dengan tingkat derau 2,0, akurasi estimasi terkendali dalam tingkat yang dapat diterima, membuktikan ketahanan KEDL terhadap derau set data pelatihan. Ketahanan derau ini disebabkan oleh fakta bahwa fungsi sub-rugi berbasis pengetahuan L_K tidak terpengaruh oleh data yang terkontaminasi.



Gambar 12.10: Kesalahan estimasi pada berbagai tingkat derau.

12.4 PENERAPAN KEDL PADA SISTEM NONLINIER

Pada bagian ini, estimasi respons berbasis jaringan saraf tiruan diterapkan pada sistem SDOF dan MDOF nonlinier untuk menyelidiki penerapannya pada estimasi respons struktural nonlinier yang realistis. Sistem SDOF nonlinier digunakan untuk menyelidiki penerapan estimasi berbasis jaringan saraf tiruan pada berbagai tingkat nonlinier. Sistem MDOF nonlinier digunakan untuk menyelidiki kemampuan generalisasi dan keunggulan efisiensi estimasi berbasis jaringan.

Penerapan pada Sistem SDOF Nonlinier


Untuk menyelidiki penerapan estimasi respons berbasis jaringan pada sistem dengan berbagai tingkat nonlinier, sistem SDOF nonlinier dengan kekakuan kubik digunakan:

$$m\ddot{u}(t) + c\dot{u}(t) + ku(t) + k_c u^3(t) = f(t) \tag{12.18}$$

dengan $m = 3,237 \times 10^6 \text{kg}$; $c = 1,515 \times 10^4 \text{Nm/s}$; $k = 1,773 \times 10^5 \text{N/m}$; dan k_c adalah kekakuan kubik. Rasio k_c/k yang berkisar antara 500 hingga 9.000 dipilih untuk merepresentasikan berbagai tingkat nonlinier.

Arsitektur LSTM bertumpuk yang disajikan pada Gambar 12.6 dilatih untuk mengestimasi respons dinamis sistem SDOF nonlinier. Respons tersebut dinormalisasi dengan nilai maksimum yang sesuai untuk perhitungan galat. Gambar 12.11a menggambarkan galat absolut rata-rata versus rasio k_c/k . Dapat diamati bahwa galat meningkat secara linear seiring dengan rasio k_c/k dan mencapai 0,066 ketika k_c/k mencapai 9.000. Hubungan positif antara galat dan rasio k_c/k disebabkan oleh kemampuan aproksimasi arsitektur jaringan saraf tiruan yang terbatas. Jumlah lapisan LSTM divariasikan dari 1 hingga 5 untuk kasus k_c/k guna

memverifikasi hipotesis ini. Seperti ditunjukkan pada Gambar 12.11b, galat berkorelasi negatif dengan jumlah lapisan LSTM. Untuk sistem dengan tingkat nonlinieritas tinggi, lebih banyak lapisan LSTM perlu ditambahkan untuk mencapai akurasi target.



Gambar 12.11: Kesalahan estimasi respons berbasis jaringan pada sistem SDOF nonlinier.

Aplikasi pada Sistem MDOF Nonlinier

Estimasi respons berbasis jaringan diterapkan pada sistem MDOF nonlinier untuk menyelidiki kemampuan generalisasi dan keunggulan efisiensinya. Lebih spesifik lagi, konfigurasi jaringan saraf tiruan [3 lapisan LSTM (masing-masing dengan 8 neuron) dan 1 lapisan padat] yang ditunjukkan pada Gambar 12.6 digunakan untuk memperkirakan respons struktural model massa tergabungan dengan kekakuan bilinear.


Konfigurasi Sistem

Pengaturan bangunan target ditunjukkan pada Gambar 12.12a. Rangka dengan penguat memiliki tinggi 78 m dan lebar serta kedalaman 25 m. Distribusi massa linier digunakan (Zhang dan rekan-rekan., 2017) sebagai berikut:


$$r_m(z_R) = 1 - 0.5z_R \tag{12.19}$$

dengan $z_R = z/H$ adalah tinggi relatif. Rasio massa lantai atas dan bawah λ_{MRTB} adalah 0,5. Kepadatan bangunan ditetapkan sebesar 220 kg/m^3 , sehingga total massa bangunan adalah $1,1 \times 10^7 \text{ kg}$. Variasi kekakuan dapat dinyatakan sebagai:

$$r_s(z_R) = 1 - (1 - 0.55)(z_R)^2 \tag{12.20}$$



(a) Schematic of the braced frame



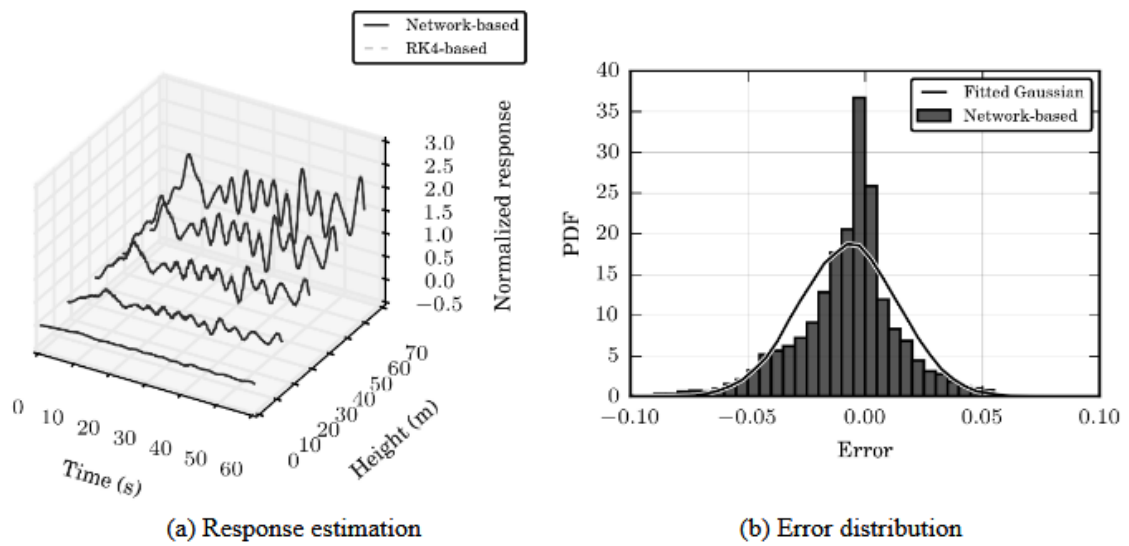
(b) Bilinear stiffness

Gambar 12.12: Konfigurasi sistem MDOF nonlinier.

Rasio kekakuan tingkat atas terhadap tingkat bawah λ_{SRTB} adalah 0,55. Frekuensi fundamental dari superstruktur linier adalah 1,25 Hz, yang setara dengan periode 0,8 s. Rasio redaman pada mode pertama diasumsikan sebesar 0,01. Kekakuan lateral bangunan target disediakan oleh bracing yang memiliki kekakuan bilinear. Bangunan diasumsikan tetap berperilaku linier di bawah beban angin dengan Mean Recurrence Interval (MRI) 300 tahun dan memiliki rasio kekakuan pasca-leleh sebesar 0,1. Beban angin dihasilkan sesuai dengan prosedur yang dijelaskan pada Bagian 3, dan metode RK4 digunakan untuk memperoleh dataset pelatihan dengan frekuensi sampling 50 Hz.

Akurasi Estimasi

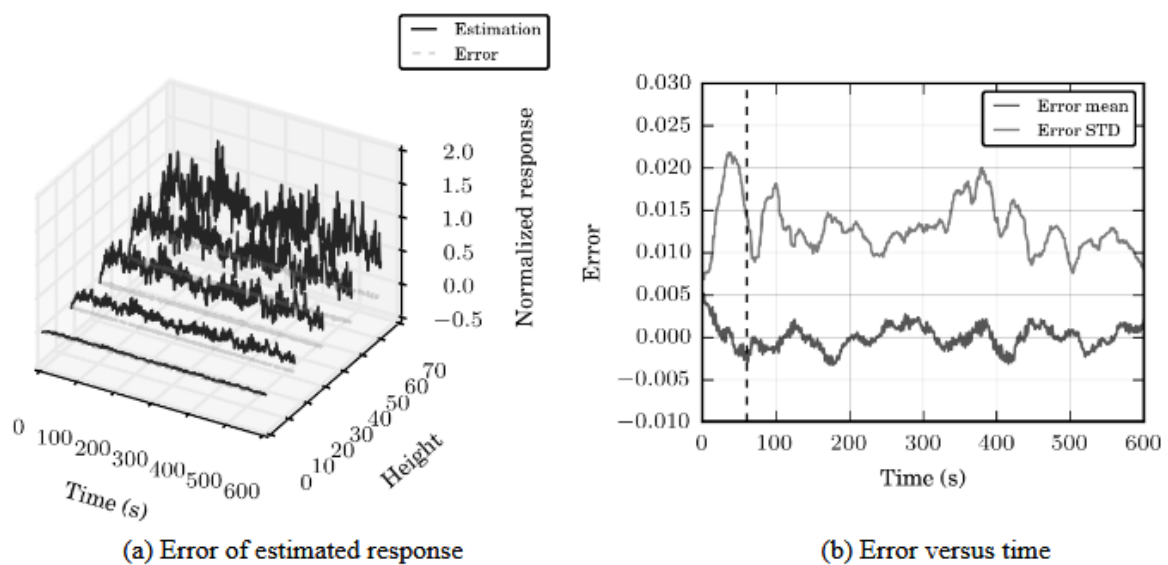
Akurasi estimasi respons berbasis jaringan diverifikasi terlebih dahulu. Seratus sampel dengan durasi 60 detik (3.000 langkah waktu diskrit) digunakan untuk melatih jaringan saraf tiruan. Gambar 12.13a menyajikan estimasi respons berbasis RK4 dan KEDL untuk berbagai tingkat bangunan. Semua respons dinormalisasi dengan deviasi standar respons ujung. Seperti ditunjukkan pada Gambar 12.13, galatnya kecil dibandingkan dengan respons berbasis RK4. Untuk menguji akurasi estimasi berbasis jaringan saraf tiruan secara umum, galat estimasi respons diestimasi dari 100 sampel uji dan disajikan pada Gambar 12.13b. Dapat ditemukan bahwa galat keseluruhannya kecil. Distribusi Gaussian yang telah disesuaikan juga disajikan pada Gambar 12.13b. Dibandingkan dengan distribusi Gaussian, kesalahannya lebih terkonsentrasi mendekati nol.



Gambar 12.13: Akurasi Estimasi Respons.

Kemampuan Generalisasi

Untuk memverifikasi kemampuan generalisasi jaringan saraf tiruan yang telah dilatih, jaringan saraf tiruan tersebut diuji dengan sampel yang memiliki durasi jauh lebih lama daripada dataset pelatihan. Secara spesifik, jaringan saraf tiruan dilatih dengan sampel berdurasi 60 detik dan diuji dengan sampel berdurasi 600 detik. Durasi analisis 600 detik telah banyak digunakan dalam analisis respons yang diinduksi angin dan oleh karena itu dipilih dalam studi ini. Estimasi berbasis jaringan saraf tiruan dan galat yang sesuai ditunjukkan pada Gambar 12.14a. Meskipun jaringan dilatih dengan sampel berdurasi 60 detik, penerapannya pada eksitasi dengan durasi 600 detik yang jauh lebih panjang menunjukkan galat tingkat rendah.




Gambar 12.14: Kemampuan generalisasi pada sampel berdurasi panjang.

Untuk menyelidiki pengaruh durasi yang lebih panjang dengan lebih baik, merata dan deviasi baku (STD) galat estimasi perpindahan puncak terhadap waktu disajikan pada Gambar 12.14b. Dapat diamati bahwa galatnya umumnya rendah (3% dari STD). Dibandingkan dengan data 0–60 detik (ditandai dengan garis vertikal putus-putus), data 60–600 detik menunjukkan peningkatan kesalahan yang tidak signifikan. Hal ini menunjukkan bahwa jaringan telah berhasil mempelajari hubungan eksitasi-respons struktural.

Efisiensi Estimasi

Keuntungan utama estimasi respons nonlinier berbasis jaringan saraf tiruan adalah efisiensinya. Untuk menunjukkan efisiensi estimasi respons berbasis jaringan, 100 estimasi respons dilakukan untuk setiap gedung dengan durasi 600 detik. Dengan satu inti CPU (CPU Intel Xeon Gold 6130 @ 2,10GHz), estimasi berbasis jaringan saraf tiruan dicapai dalam waktu 0,47 jam, sementara estimasi berbasis RK4 membutuhkan waktu 2,94 jam. Distribusi konsumsi waktu untuk satu sampel disajikan pada Gambar 12.15, di mana jaringan saraf tiruan mengurangi konsumsi waktu rata-rata dari 80 detik menjadi 13 detik. Perlu dicatat bahwa jaringan saraf tiruan menggunakan ukuran batch 1 dalam perbandingan efisiensi. Dalam hal ini, operasi penyalinan data justru menghasilkan konsumsi waktu yang lebih lama dibandingkan dengan eksekusi instruksi. Dengan hanya meningkatkan ukuran batch, waktu estimasi rata-rata berbasis jaringan saraf tiruan dapat dikurangi lebih lanjut. Misalnya, dengan meningkatkan ukuran batch menjadi 200, konsumsi waktu rata-rata untuk setiap sampel dapat dikurangi menjadi 0,62 detik.



Gambar 12.15: Konsumsi waktu untuk satu sampel.

12.5 KESIMPULAN

Kemajuan dalam DL memberikan gambaran tentang penggunaan ANN untuk estimasi respons struktur nonlinier yang efisien. Dalam studi ini, arsitektur LSTM bertumpuk diusulkan untuk mengaproksimasi hubungan eksitasi-respons struktur nonlinier dalam domain wavelet. Untuk mengatasi masalah permintaan data pelatihan yang tinggi, metodologi KEDL berbasis persamaan digunakan. Dalam KEDL, rumus berbasis fisika dan empiris digunakan bersama-sama untuk mengatur proses pelatihan dan mengurangi permintaan data.

Metode berbasis jaringan yang dikembangkan menunjukkan hasil yang sangat menjanjikan dalam estimasi respons struktural nonlinier yang efisien dan akurat, terutama jika data pelatihan memiliki durasi yang lebih pendek dibandingkan dengan data pengujian. Metodologi KEDL juga menunjukkan ketahanan yang tinggi terhadap derau dalam data pelatihan. Metodologi KEDL diharapkan akan memfasilitasi penerapan teknik DL dalam analisis keselamatan struktur dan infrastruktur sipil.

BAB 13

DETEKSI KERUSAKAN BETON DENGAN FINITE ELEMENT DAN AI

13.1 PENDAHULUAN

Kerusakan struktural pada sistem infrastruktur yang menua menjadi masalah yang semakin penting di seluruh dunia. Kondisi ekonomi yang terbatas membatasi sumber daya yang tersedia untuk perbaikan atau penggantian sistem tersebut. Selama beberapa dekade terakhir, pemantauan kesehatan struktural (SHM) telah terbukti menjadi alat yang hemat biaya untuk mendeteksi dan mengevaluasi kerusakan pada struktur. Inspeksi visual dan penilaian kondisi merupakan salah satu teknik SHM yang paling banyak diterapkan. Namun, efektivitas SHM bervariasi tergantung pada ketersediaan dan pengalaman personel yang berkualifikasi dan sebagian besar evaluasi kerusakan kualitatif.

Sebagian besar peneliti sepakat untuk menggunakan parameter referensi yang diekstraksi dari balok yang sehat sebagai pembanding. Namun, mereka berbeda dalam mendefinisikan parameter ini, yang dapat dikategorikan menjadi parameter dinamis dan statis. Ndambi dan rekan-rekan. (2002) menyelidiki potensi penggunaan frekuensi Eigen dan properti turunan bentuk mode untuk mendeteksi lokasi dan memperkirakan tingkat keparahan kerusakan pada balok beton bertulang.

Hasil pengujian mereka menunjukkan bahwa frekuensi Eigen komponen beton bertulang dapat dikorelasikan secara numerik dengan perubahan kekakuan, sehingga kerusakan dapat dikuantifikasi dengan metode uji non-destruktif. Teughels dan rekan-rekan. (2002) menyajikan pendekatan kuantifikasi kerusakan menggunakan pembaruan model Elemen Hingga (FE). Hasil penelitian ini menunjukkan bahwa properti modal dapat digunakan dengan teknik pemrosesan dan analisis, seperti pembaruan model FE, untuk mengkuantifikasi kerusakan secara andal pada struktur beton bertulang. Ghods dan Esfahani (2009) melakukan uji pembebanan statis dan analisis modal dinamis pada delapan balok beton bertulang dengan berbagai kekuatan tekan dan rasio tulangan.

Eksperimen ini menyoroti kemampuan analisis modal untuk mengkarakterisasi tingkat kerusakan spesifik pada balok beton bertulang. Reynders dan De Roeck (2009) menerapkan parameter analisis modal untuk mengembangkan metode penilaian kerusakan berbasis fleksibilitas untuk komponen balok. Kesimpulannya adalah bahwa metode fleksibilitas berbasis data modal menunjukkan hasil yang menjanjikan sebagai metode nondestruktif untuk mengkuantifikasi kerusakan pada balok beton. Tan dan rekan-rekan. (2020) mengembangkan dan menerapkan prosedur untuk mendeteksi kerusakan pada struktur jembatan pelat-pada-girder komposit yang terdiri dari pelat beton bertulang dan tiga balok baja I, menggunakan karakteristik getaran dan Jaringan Syaraf Tiruan (JST). Prosedur ini diterapkan pada berbagai skenario kerusakan dan hasilnya mengonfirmasi kelayakannya untuk mendeteksi dan mengkuantifikasi kerusakan pada pelat beton komposit pada jembatan girder baja.

Para peneliti juga telah menggunakan metode respons gelombang untuk melokalisasi dan mengukur kerusakan pada struktur beton bertulang. Salah satu metode tersebut, emisi

akustik (AE), menggunakan pembebanan mekanis untuk menyebabkan bagian material yang rusak memancarkan gelombang elastis yang dibaca oleh sensor permukaan. Sagar dan rekan-rekan. (2012) menggunakan teknik AE untuk menilai kerusakan pada tiga balok beton bertulang eksperimental yang mengalami tahap pembebanan siklik. Empat sensor AE dipasang pada setiap balok untuk mengumpulkan data respons gelombang selama setiap siklus pembebanan untuk mengevaluasi tingkat keparahan kerusakan pada balok.

Meskipun percobaan dibatasi pada tiga balok eksperimental, para peneliti mengusulkan bahwa teknik AE menunjukkan potensi yang signifikan untuk aplikasi penilaian kerusakan struktural. Shiotani dan rekan-rekan. (2012) menggunakan teknik AE dan tomografi gelombang elastis untuk menilai kesehatan struktural dek jembatan beton bertulang eksperimental yang mengalami kerusakan fatik. Beban fatik disimulasikan dengan tahapan beban 0, 10.000, dan 20.000 lintasan beban roda bergerak 100 kN, dan data gelombang direkam untuk dek jembatan di bawah langkah beban statis inkremental setelah setiap tahapan beban fatik.

Tomografi gelombang elastis dan analisis AE dari dua dek jembatan in situ memperkuat temuan mereka, dan kecepatan gelombang dan frekuensi alami kembali menunjukkan harapan besar sebagai parameter kuantifikasi kerusakan. Ongpeng dan rekan-rekan. (2019) memantau kerusakan pada 18 balok beton bertulang dengan rasio air semen yang bervariasi dan tulangan yang diuji di bawah uji lentur empat titik. Beban langkah berulang dirancang dan pada setiap beban langkah, sinyal AE direkam dan diproses untuk mendapatkan lokasi sumber emisi akustik (AESL). Volume lambung cembung (CHV) yang dihitung menunjukkan hubungan yang baik dengan kerusakan yang ditemui hingga 60% dari beban ultimit di bentang tengah tercapai.

Para peneliti juga telah memanfaatkan teknik pencitraan digital seperti korelasi citra digital (DIC), deteksi cahaya dan pengukuran jarak (LiDAR), dan analisis fraktal untuk mengevaluasi kerusakan pada struktur beton bertulang. DIC bergantung pada algoritma yang memproses data dari citra resolusi tinggi untuk mengukur perpindahan dan regangan permukaan. Li dan rekan-rekan. (2008) menggunakan DIC untuk mendeteksi retakan dan menilai kerusakan pada beberapa balok beton bertulang eksperimental. Model Loland dipilih untuk mengkuantifikasi kerusakan dan evolusi kerusakan, dan data yang direkam melalui DIC diterapkan dalam pembaruan model FE untuk menentukan kerusakan awal dan parameter material dalam model yang rusak.

Hasil percobaan ini menunjukkan bahwa DIC yang dikombinasikan dengan teknik seperti pembaruan model FE dapat secara efektif mengkuantifikasi kerusakan struktural. Aplikasi teknologi LiDAR 3D dalam deteksi dan kuantifikasi kerusakan diselidiki dalam tiga studi kasus yang dirangkum oleh Chen dan rekan-rekan. (2012). Satu studi kasus jembatan di Iowa menyoroiti kemampuan LiDAR tidak hanya untuk mendeteksi retakan, tetapi juga untuk menggambarkan lokasi dan dimensinya secara tepat.

Para peneliti juga telah menyelidiki fusi ANN dan pendekatan pembaruan model FE. Jeyasehar dan Sumangala (2006) menyelidiki kemampuan ANN untuk memprediksi kerusakan secara kuantitatif dalam sebuah eksperimen yang melibatkan lima balok beton prategang

pasca-tegang. Kerusakan pada balok disebabkan oleh putusnya kawat dengan persentase variabel melalui induksi korosi pitting lokal pada pembentuk retak yang ditempatkan di tengah balok, dan balok-balok tersebut mengalami tahapan pembebanan statis dengan besaran yang semakin meningkat.

Hasil penelitian menunjukkan bahwa kesalahan penilaian tingkat kerusakan dapat dikurangi dengan pengenalan data uji statis ke dalam ANN, alih-alih data uji dinamis. Hasançebi dan Dumlupinar (2013) membahas potensi penggunaan ANN untuk melakukan operasi pembaruan model FE pada jembatan balok-T beton bertulang. Para peneliti mengembangkan model jembatan FE analitis dengan berbagai kekakuan batas, modulus elastisitas, dan massa dek. Perubahan sifat-sifat ini dari keadaan awal digunakan untuk mengkarakterisasi kerusakan dan menilai kesehatan struktur. Para peneliti menyimpulkan bahwa ANN dapat berhasil digunakan bersamaan dengan pembaruan model FE untuk mengevaluasi kerusakan secara kuantitatif, asalkan keduanya memanfaatkan hasil uji statis dan dinamis.

Bab ini mengusulkan pemanfaatan sinergi antara simulasi Elemen Hingga (FE) dan kekuatan pemodelan serta prediksi Kecerdasan Buatan (AI) untuk mewujudkan pergeseran paradigma dalam kualitas evaluasi pemantauan kesehatan struktural yang otomatis dan objektif serta kemampuan deteksi kerusakan cerdas. Simulasi FE berfungsi sebagai alat numerik untuk menetapkan hubungan antara penurunan kekakuan spasial pada simpul-simpul diskrit pada gelagar yang rusak dan retakan atau kerusakan aktual pada komponen beton bertulang tersebut.

Tujuannya adalah untuk memodelkan hubungan ini menggunakan AI untuk memulihkan satu set parameter dalam kaitannya dengan yang lainnya. Keunggulan sinergi ini adalah mengembangkan hubungan basis data yang diperlukan untuk menyelesaikan dua masalah yang sepenuhnya independen dengan aplikasi terpisah, yaitu:

1. Masalah Maju: Dalam masalah ini, metodologi objektif ditetapkan untuk mengekstrak parameter indeks kesehatan yang unik dari pengukuran aktual distribusi retakan yang dapat diakses pada gelagar beton bertulang. Dengan menggunakan model numerik dengan kerusakan fisik untuk menghasilkan degradasi kekakuan di sepanjang girder yang rusak sebagai rasio dari kekakuan yang sehat, estimasi degradasi kekakuan yang robust dapat diperoleh. Penerapan permasalahan ini berkaitan dengan inspeksi tahunan girder yang kerusakannya dapat diakses dan diukur oleh inspektur. Permasalahan ini lebih mudah ditangani sehingga dapat dikembangkan lebih lanjut.
2. Permasalahan Invers: Dalam permasalahan ini, metodologi objektif ditetapkan untuk mengekstraksi distribusi kerusakan potensial berdasarkan pola penurunan kekakuan tertentu di sepanjang girder. Dengan menggunakan model numerik dengan kerusakan fisik untuk menghasilkan pola penurunan kekakuan di sepanjang girder yang rusak sebagai rasio dari kekakuan yang sehat, estimasi potensial retakan atau kerusakan yang mungkin terjadi dapat diusulkan jika pola penurunan kekakuan teridentifikasi. Penerapan permasalahan ini berkaitan dengan deteksi kerusakan pada girder yang tidak dapat diakses yang melintasi sungai dan anak sungai sementara permukaan atas

girder berada dalam jangkauan. Untuk menghasilkan profil penurunan kekakuan, sebuah model numerik dibuat untuk meniru respons girder yang sehat, sementara pengukuran lapangan diterapkan untuk mengekstrak respons girder yang rusak. Hal ini dapat dilakukan dengan menggunakan teodolit, skala titik, dan kendaraan yang menginduksi berat yang diketahui. Permasalahan ini tidak menghasilkan solusi tunggal sehingga lebih sulit untuk diatasi. Oleh karena itu, permasalahan ini menjadi fokus perhatian dan pembahasan bab ini.

Untuk membuktikan penerapan konsep ini, seluruh rangkaian model numerik dikaji di sini. Pertama, balok beton bertulang dua dimensi dengan penampang persegi panjang digunakan untuk memodelkan komponen yang rusak dalam bentuk elemen balok dan jaring FE 2D. Kemudian, balok beton bertulang 3D dengan penampang T digunakan untuk memodelkan komponen yang rusak dalam bentuk jaring FE padat 3D. Basis data mencakup variasi parameter geometri dan material balok serta sifat retak dalam bentuk lokasi retak, kedalaman retak, dan lebar retak.

Semua simulasi numerik balok dan elemen hingga dilakukan dalam program elemen hingga multi-fisika Abaqus. Pada bagian selanjutnya, pengantar pemodelan ANN, metodologi teknik AI-FE, dan pembentukan basis data analisis elemen hingga 2D dan 3D disajikan secara rinci. Bagian-bagian yang menyoroti hasil dan pembahasan, contoh numerik, dan pengembangan perangkat lunak akan menyusul. Terakhir, ringkasan bab disediakan yang merangkum temuan dan mencantumkan rekomendasi untuk pengembangan saat ini dan di masa mendatang.

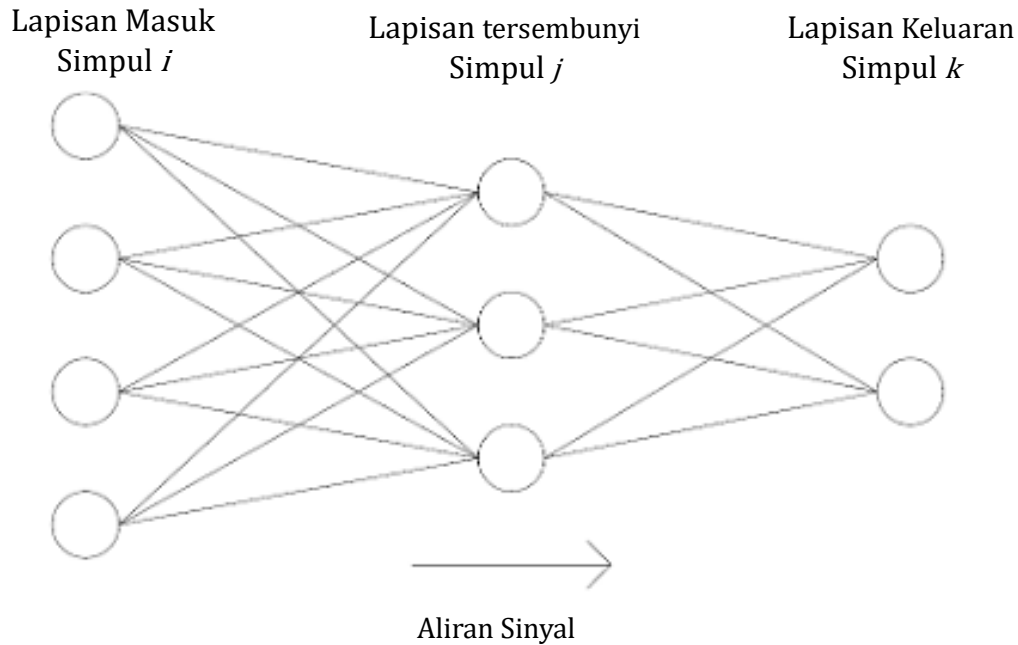
13.2 JARINGAN SYARAF TIRUAN

Jaringan Syaraf Tiruan (JST) adalah sistem komputasi yang dirancang untuk mensimulasikan bagaimana otak manusia menerima, memproses, dan menyimpulkan informasi. Akurasi JST, seperti halnya otak manusia, sangat bergantung pada jumlah paparan/himpunan data yang dialami. Himpunan data yang lebih besar biasanya menghasilkan jaringan dengan akurasi prediksi yang lebih tinggi dibandingkan dengan JST yang dihasilkan dari data terbatas. Proses pembelajaran ini memungkinkan JST untuk menggeneralisasi hubungan nonlinier yang kompleks untuk skenario yang tidak diuji dalam fase pembelajaran tanpa ekstrapolasi informasi masukan.

Struktur dan Teknik Pembelajaran

JST dibangun dengan simpul neuron yang saling terhubung seperti jaring (Gambar 13.1). Simpul-simpul ini bertanggung jawab untuk memproses informasi secara paralel dan biasanya dibagi menjadi beberapa lapisan atau kluster. Distribusi lapisan-lapisan ini dan bagaimana mereka berinteraksi satu sama lain, serta interkoneksi di dalam setiap lapisan, menghasilkan struktur JST dan teknik pembelajaran yang tak terhitung jumlahnya. Sebagian besar struktur jaringan terdiri dari setidaknya tiga lapisan simpul: lapisan masukan, satu atau lebih lapisan tersembunyi, dan lapisan keluaran, Gambar 13.1. Lapisan masukan menyediakan informasi yang mendefinisikan atau pengantar ke ANN. Di sisi lain, lapisan tersembunyi bertanggung jawab atas proses pembelajaran melalui beberapa operasi matematika yang

dilakukan dalam lapisan tersembunyi ini dan bobot koneksinya ke lapisan masukan dan keluaran. Akhirnya, lapisan keluaran mengekstrak hasil dari ANN. Dua jenis utama struktur ANN adalah arsitektur feedforward (statis) dan rekursif (dinamis).



Gambar 13.1: Arsitektur ANN umpan maju umum.

Dalam jaringan feedforward, aliran sinyal bersifat searah dari lapisan masukan → keluaran, dan simpul pada lapisan berbeda tidak saling terhubung (lihat Gambar 13.1). Pada jaringan rekursif, simpul dalam lapisan dapat saling terhubung, dan sinyal keluaran ditransmisikan kembali ke ANN dalam berbagai konfigurasi loop. Untuk kejelasan, setiap simpul pada lapisan masukan dilabeli sebagai simpul (i), setiap simpul pada lapisan tersembunyi sebagai simpul (j), dan setiap simpul pada lapisan keluaran sebagai simpul (k) (lihat Gambar 13.1). Selain itu, penting dicatat bahwa istilah masukan (I) dan keluaran (O) dalam pembahasan ini merujuk masing-masing pada awal dan akhir suatu proses.

Ada tiga teknik pembelajaran umum yang biasanya diikuti oleh proses ANN. Teknik-teknik ini diklasifikasikan berdasarkan algoritma evaluasi akurasi keluaran. Ketiga teknik pembelajaran ini adalah pembelajaran terawasi, pembelajaran terinternalisasi, dan pembelajaran tak terawasi. Keluaran/prediksi dalam pembelajaran terawasi dinilai berdasarkan data aktual dalam fase pelatihan. Kesalahan yang terkait dengan prediksi ini kemudian digunakan untuk menyesuaikan bobot koneksi demi akurasi yang lebih tinggi. Pembelajaran terinternalisasi umumnya mirip dengan pembelajaran terawasi, namun, hanya evaluasi kualitas keluaran yang diprediksi yang digunakan untuk menyesuaikan bobot koneksi dan keluaran aktual tidak diberikan kepada ANN. Dalam metode tanpa pengawasan, pembelajaran terjadi ketika jaringan mengeksplorasi pola dalam data masukan dan membangun korelasi. Metode invers yang dibahas dalam bab ini mengadaptasi ANN berbasis pembelajaran terawasi umpan-maju.

Prosedur Persiapan dan Pelatihan Data

Kumpulan data yang digunakan untuk membangun JST dibagi menjadi tiga fase: pelatihan, pengujian, dan validasi. Kumpulan data pelatihan berfungsi sebagai langkah pertama dalam proses pembelajaran. Pada langkah ini, JST melewati serangkaian iterasi penyesuaian bobot koneksi. Sangat penting untuk menetapkan entri kumpulan data yang berisi nilai minimum dan maksimum parameter input pada langkah pelatihan guna memastikan eksposur penuh untuk JST dan interpolasi yang bermakna, alih-alih ekstrapolasi, dari kejadian input baru.

Setelah menetapkan bobot koneksi yang sesuai, JST menjalani evaluasi untuk memprediksi akurasi jaringan pada kumpulan pengujian. Kedua langkah ini diterapkan untuk banyak JST dengan arsitektur yang berbeda (misalnya, jumlah lapisan tersembunyi) dan konfigurasi (misalnya, laju pembelajaran). Untuk memilih JST yang optimal, arsitektur jaringan dengan kinerja terbaik dari tahap pelatihan dan pengujian dievaluasi ulang pada kumpulan data validasi.

Proses pelatihan JST dapat digambarkan sebagai proses coba-coba. Setiap simpul pada lapisan masukan terhubung ke setiap simpul pada lapisan tersembunyi, dan bobot koneksi antar simpul ditetapkan secara acak pada iterasi pertama.

Simpul tersembunyi ke- j menerima sinyal keluaran O_j yang merupakan penjumlahan dari nilai masukan I_i dikalikan dengan bobot koneksinya w_{ji} , kemudian ditambah bias b_j atau ambang batas yang terkait dengan simpul tersembunyi j . Persamaan dituliskan sebagai berikut:

$$o_j = \sum_{i=1}^n w_{ji}I_i + b_j \quad (13.1)$$

di mana:

O_j = nilai keluaran untuk simpul j

w_{ji} = bobot koneksi antara simpul i pada lapisan masukan dan j pada lapisan tersembunyi

I_i = nilai masukan pada simpul i pada lapisan masukan

b_j = bias untuk simpul j pada lapisan tersembunyi

Fungsi aktivasi kemudian memproses sinyal baru dari simpul tersembunyi (j) untuk menghilangkan nilai yang besar atau negatif dan mengekspos JST pada nonlinier. Fungsi aktivasi yang digunakan oleh JST dalam bab ini adalah fungsi sigmoid. Fungsi ini menormalkan nilai baru pada simpul tersembunyi di bawah (-5) menjadi sekitar -0 dan di atas (5) menjadi sekitar 1 , lihat Gambar 13.2. Dalam rentang nilai $(-5, 5)$, fungsi ini menghasilkan variasi nonlinier dalam rentang $(0,1)$. Fungsi sigmoid diterapkan menggunakan persamaan berikut sambil menetapkan setiap O_j dari Persamaan (13.1) untuk diberi nama I_j sekarang:


$$O_j = f(I_j) = \frac{1}{1 + e^{-I_j}} \quad (13.2)$$

O_j = keluaran fungsi aktivasi pada simpul j lapisan tersembunyi

$f(I_i)$ = fungsi aktivasi sigmoidal

I_j = nilai komputasi untuk simpul j lapisan tersembunyi, awalnya O_j .

Keluaran dari fungsi aktivasi pada lapisan tersembunyi O_j terlebih dahulu dinamakan ulang menjadi I_j . Selanjutnya, nilai I_j ini dikalikan dengan bobot koneksinya, kemudian dijumlahkan, dan ditambahkan dengan bias yang terkait pada simpul-simpul lapisan keluaran.



Gambar 13.2: Plot fungsi sigmoid.

Dari proses tersebut diperoleh nilai baru untuk lapisan keluaran O_k lihat Persamaan (13.3):

$$O_k = \sum_{j=1}^n w_{kj} I_j + b_k \quad (13.3)$$

Nilai-nilai yang dihasilkan kemudian diproses oleh fungsi aktivasi dan didenormalisasi untuk memberikan nilai keluaran yang diprediksi untuk ANN, setelah menetapkan (O_k) menjadi (I_k).

$$O_k = f^{-1}(I_k) = \ln\left(\frac{I_k}{1 - I_k}\right) \quad (13.4)$$

Faktor kesalahan dihitung dan digunakan untuk menghitung penyesuaian bobot sambungan tambahan yang diperlukan sesuai dengan persamaan berikut:

$$\Delta w_{ij} = \eta \delta_k O_j + \mu \Delta w_{ij}^{previous} \quad (no \ sum \ on \ k) \quad (13.5)$$

Dimana:

$$\delta_k = (y_k - O_k)(1 - O_k)O_k \quad (13.6)$$

Δw_{kj} = penyesuaian bobot koneksi inkremental antara simpul j pada lapisan tersembunyi dan simpul k pada lapisan keluaran

η = laju pembelajaran

δ_k = faktor kesalahan simpul k pada lapisan keluaran

μ = laju momentum

$\Delta w_{kj}^{previous}$ = penyesuaian inkremental bobot koneksi dari iterasi sebelumnya

Y_k = nilai aktual pada simpul keluaran k pada lapisan keluaran

Perubahan inkremental pada bias lapisan keluaran juga dihitung dengan persamaan berikut:

$$\Delta b_k = \eta \delta_k + \mu \Delta b_k^{previous} \quad (13.7)$$

di mana:

Δb_k = penyesuaian bias inkremental untuk simpul k pada lapisan keluaran

$\Delta b_k^{previous}$ = penyesuaian bias inkremental untuk simpul k dari iterasi sebelumnya

Demikian pula, faktor kesalahan dihitung untuk simpul tersembunyi menggunakan persamaan berikut:

$$\delta_j = \left(\sum_{k=1}^n \delta_k w_{kj} \right) (1 - O_j) O_j \quad (13.8)$$

di mana:

δ_k = faktor kesalahan simpul keluaran k yang dihitung dengan Persamaan (13.6)

w_{kj} = bobot koneksi antara simpul tersembunyi dan simpul keluaran

O_j = nilai prediksi pada simpul j dari lapisan tersembunyi dari Persamaan (13.1)

δ_j = faktor kesalahan simpul tersembunyi j yang dihitung dengan Persamaan (13.8)

Dengan demikian, penyesuaian bobot koneksi inkremental antara simpul masukan dan simpul tersembunyi adalah:

$$\Delta w_{ji} = \eta \delta_j O_i + \mu \Delta w_{ji}^{previous} \quad (no \ sum \ on \ j) \quad (13.9)$$

Demikian pula,

$$\Delta b_j = \eta \delta_j + \mu \Delta b_j^{previous} \quad (13.10)$$

Bobot dan bias koneksi diperbarui untuk semua simpul dalam jaringan, dan seluruh proses diulang untuk setiap set data pelatihan hingga jumlah iterasi pelatihan yang telah ditentukan tercapai atau kesalahan keluaran berkurang ke tingkat yang dapat diterima. JST menyelesaikan iterasi ini pada rentang simpul tersembunyi yang ditentukan oleh pengguna. Penggunaan simpul tersembunyi yang terlalu sedikit dapat mengakibatkan arsitektur jaringan yang tidak dapat menyelesaikan masalah tergantung pada kompleksitasnya, sementara penggunaan simpul tersembunyi yang terlalu banyak dapat mengakibatkan overtraining, atau menghafal, data. Jumlah maksimum absolut simpul tersembunyi dihitung dengan persamaan berikut:

$$MHN = \frac{TR - O}{I + O + 1} \tag{13.11} \quad 13.11$$

di mana:

MHN = jumlah maksimum simpul tersembunyi

TR = jumlah set data pelatihan

O = jumlah parameter keluaran

I = jumlah parameter masukan

Kriteria Pemilihan Model Optimum

Model JST biasanya dievaluasi berdasarkan beberapa ukuran statistik, termasuk koefisien determinasi (R^2), galat relatif absolut rata-rata (MARE), dan galat kuadrat rata-rata (ASE). Ukuran-ukuran ini dihitung dengan persamaan berikut:

$$R^2 = \frac{1}{o} \sum^n \left(\frac{n \sum^n xy - \sum^n x \sum^n y}{\sqrt{n \sum^n x^2 - (\sum^n x)^2} \sqrt{n \sum^n y^2 - (\sum^n y)^2}} \right)^2 / o \tag{13.12}$$

$$MARE(\%) = \frac{\sum^o \sum^n \left(\frac{|y - x|}{x} \times 100 \right)}{o \times n} \tag{13.13}$$

$$ASE = \frac{\sum^o \sum^n (y - x)^2}{o * n} \tag{13.14}$$

di mana:

x = nilai aktual suatu parameter

y = nilai prediksi parameter ANN

o = jumlah keluaran

n = jumlah himpunan data


ANN yang lebih efektif biasanya dicirikan oleh nilai MARE dan ASE yang rendah serta nilai R^2 yang tinggi. Kemampuan prediksi ANN yang menampilkan kinerja statistik optimal dan

memanfaatkan simpul tersembunyi paling sedikit selama fase pelatihan dan pengujian dinilai ulang dengan dataset validasi. Jika model optimal berkinerja baik dalam fase validasi, ANN kemudian dilatih ulang pada semua dataset sehingga prediksi dapat dibuat menggunakan arsitektur jaringan optimal yang dilatih dengan keseluruhan data yang tersedia.

13.3 METODOLOGI SINERGI AI-FE

Untuk menerapkan perlakuan AI pada masalah invers deteksi kerusakan yang dijelaskan sebelumnya di bagian pendahuluan bab ini, analisis FE dilakukan untuk memodelkan profil penurunan kekakuan girder tersebut. Untuk pekerjaan ini, Abaqus FEA dipilih sebagai paket perangkat lunak analisis struktural yang paling tepat karena kemampuan ekstensibilitas dan skripnya (Dokumentasi Daring Abaqus 6.10, 2010).

Sebagaimana akan dibahas nanti dalam bab ini, hal ini penting mengingat banyaknya model yang perlu dihasilkan untuk mendapatkan kumpulan data yang akan digunakan dalam proses pelatihan jaringan saraf tiruan. Retak pada girder dimodelkan dengan perubahan penampang balok yang ditopang secara sederhana seperti yang ditunjukkan pada Gambar 13.3. Parameter retak yang digunakan dalam pemodelan meliputi kedalaman (d_{cr}), lebar (w_{cr}), dan lokasi (b_{cr}) retakan. Prosedur ini dapat diperluas ke konfigurasi balok lainnya, seperti balok kontinu multibentang (Al-Rahmani dan rekan-rekan., 2013).




Gambar. 13.3: Elevasi balok beton yang menunjukkan parameter retak yang dipertimbangkan dalam analisis.

Baik model FE 2D maupun 3D dihasilkan dalam penelitian ini. Kesederhanaan model 2D yang relatif memberikan titik awal yang sangat baik untuk membangun basis data kerusakan untuk metode ini dalam waktu yang lebih singkat. Di sisi lain, model 3D memungkinkan untuk memperluas pendekatan ini lebih jauh dan mengembangkan model yang lebih akurat yang merepresentasikan gelagar jembatan di dunia nyata. Dimulai dengan pemodelan 2D, balok dimodelkan dalam tiga fase. Balok dengan satu dan dua retakan dimodelkan masing-masing dalam fase I dan II. Untuk kedua fase ini, balok kubik 2-node dalam elemen bidang (B23), yang menggunakan asumsi Euler-Bernoulli klasik dan menggunakan fungsi interpolasi kubik, dipilih untuk memodelkan segmen balok dalam Abaqus FEA.

Diketahui bahwa asumsi ini tidak berlaku untuk elemen non-ramping; namun, karena keterbatasan waktu dan daya komputasi, hilangnya akurasi yang diperkirakan akibat penggunaan elemen ini dianggap berada dalam toleransi untuk tujuan analisis 2D. Selain itu, kesalahan yang dihasilkan diharapkan tidak akan memengaruhi hasil secara signifikan karena nilai yang diperoleh akan dinormalisasi sebagaimana akan dijelaskan nanti di bab ini. Oleh

karena itu, tulangan baja tidak disertakan dalam kedua fase ini. Jaring FE yang dikembangkan untuk model ini mencakup dua jenis elemen: elemen sehat dan elemen retak. Elemen sehat, yang mewakili bagian balok yang sehat, memiliki kedalaman yang sama dengan balok, sementara elemen retak memiliki kedalaman yang lebih rendah untuk mewakili retakan. Representasi visual jaring ditunjukkan pada Gambar 13.4.



Gambar 13.4: Jaring elemen hingga untuk fase I, II.

Untuk fase III, elemen segiempat tegangan bidang biquadratik 8-simpul (CPS8) dan elemen segitiga tegangan bidang kuadratik 6-simpul (CPS6) digunakan dalam pemodelan balok dengan retak tunggal. Selain itu, tulangan baja juga disertakan dalam analisis kali ini. Rasio baja tetap (ρ) sebesar 1% diasumsikan untuk balok yang dianalisis. Untuk menentukan ukuran jaring optimal, analisis sensitivitas dilakukan. Ukuran jaring yang dievaluasi adalah 100 mm, 50 mm, 25 mm, dan 10 mm. Balok sehat dengan lebar 250 mm, kedalaman 500 mm, panjang bentang 3,5 m, dan kuat tekan 21 MPa dianalisis sebagai referensi. Selanjutnya, dua balok retak dengan parameter geometri dan material yang sama serta parameter retak yang berbeda dimodelkan.


Balok pertama (C1) memiliki retakan sedalam 200 mm dan lebar 2,5 mm yang terletak 1,4 m dari tumpuan kiri balok, sedangkan balok kedua (C2) memiliki retakan sedalam 375 mm dan lebar 5 mm yang terletak 0,7 m dari tumpuan kiri balok. Rasio kekakuan dihitung pada 5 titik simpul kekakuan untuk setiap balok dengan memvariasikan ukuran mata jaring. Persentase perubahan rasio kekakuan (didefinisikan nanti dalam bab ini) dari ukuran mata jaring 1 (MS1) ke ukuran mata jaring 2 (MS2) ditunjukkan pada Tabel 13.1.

Secara keseluruhan, variasi yang diperoleh kurang dari 1%. Perlu dicatat bahwa menjalankan analisis untuk model dengan elemen mesh 100 mm membutuhkan waktu seperempat waktu yang dibutuhkan untuk menyelesaikan model dengan elemen 10 mm. Ukuran mesh 50 mm dipilih sebagai pilihan tengah karena memberikan akurasi yang dapat diterima dengan waktu proses yang wajar. Gambar 13.5 menunjukkan mesh yang dihasilkan secara otomatis oleh Abaqus untuk balok dengan ukuran mesh 50 mm.

Tabel 13.1: Hasil analisis sensitivitas pemodelan 2D.

	MS1	MS2	$\Delta k1$ (%)	$\Delta k2$ (%)	$\Delta k3$ (%)	$\Delta k4$ (%)	$\Delta k5$ (%)
C1	100	50	0.32722%	1.03696%	0.85103%	0.43108%	0.05413%
	50	25	0.33583%	0.83787%	0.72907%	0.36756%	0.01824%
	25	10	0.26779%	0.71102%	0.66568%	0.36886%	0.28775%
C2	100	50	0.58492%	0.70983%	0.33187%	0.17025%	0.04872%
	50	25	0.85723%	0.44899%	0.22606%	0.06457%	-0.04472%

25	10	0.69113%	0.86437%	0.43349%	0.23939%	0.13328%
----	----	----------	----------	----------	----------	----------



Gambar 13.5: Jaring elemen hingga untuk balok dalam fase III.

Model material elastis digunakan untuk memodelkan baja dan beton dalam penelitian ini. Baja dimodelkan sebagai material elastis linier dengan rasio Poisson (ν) sebesar 0,3 dan modulus elastisitas (E) sebesar 200 GPa. Beton juga dimodelkan menggunakan model material elastis linier dengan rasio Poisson (ν) sebesar 0,2 dan modulus elastisitas (E) yang dihitung dengan persamaan berikut:

$$E = 4723\sqrt{f'_c} \quad (13.15)$$

di mana:

E = modulus elastisitas (MPa)

f'_c = kuat tekan beton 28 hari (MPa)

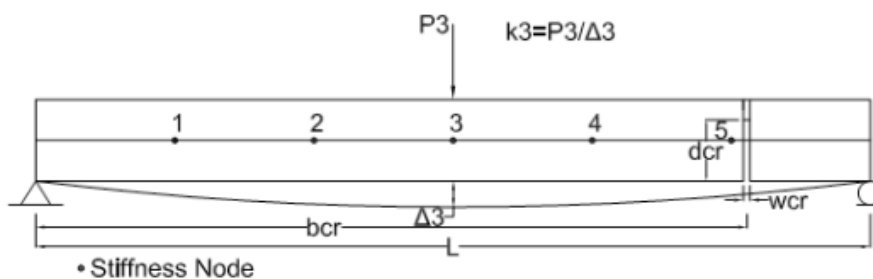
Pada semua fase, sejumlah simpul kekakuan tertentu ditambahkan ke jaring seperti yang ditunjukkan pada Gambar 13.6 (pada fase III, simpul kekakuan ditambahkan ke permukaan atas balok). Beban yang ditentukan diterapkan pada setiap simpul kekakuan dan simpangan yang dihasilkan diperoleh dari analisis seperti yang ditunjukkan pada Gambar 13.6 hingga Gambar 13.8. Akhirnya, kekakuan pada simpul dihitung dengan membagi beban yang diberikan dengan simpangan yang diperoleh pada simpul tersebut sesuai dengan persamaan berikut:

$$k_n = P_n/\Delta_n \quad (13.16)$$


di mana: k_n = nilai kekakuan pada simpul n

P_n = beban yang diberikan pada simpul n


Δ_n = lendutan yang diperoleh pada simpul n



Gambar 13.6: Elevasi balok dengan 5 titik kekakuan pada fase 1.



Gambar 13.7: Tampilan 3D balok beton dari fase II yang dibebani di pusat di Abaqus.



Gambar 13.8: Tampilan elevasi balok dari fase III di Abaqus.

Hal ini dilakukan untuk balok sehat dan balok retak guna menentukan rasio kekakuan, yang diperoleh dengan membagi kekakuan retak dengan kekakuan sehat pada setiap titik untuk balok dengan parameter geometri dan material yang sama, seperti yang ditunjukkan pada rumus berikut:

$$k_n \% = k_{n_{cr}} / k_{n_h} \quad (13.17)$$

di mana:

$k_n \%$ = rasio kekakuan pada simpul n


$k_{n_{cr}}$ = nilai kekakuan pada simpul n pada balok yang retak

k_{n_h} = nilai kekakuan pada simpul n pada balok yang sehat


Rasio kekakuan ($k_n\%$) berfungsi sebagai indikator lokal tingkat keparahan kerusakan pada balok dan dapat menunjukkan letak retakan pada balok. Rasio kekakuan yang lebih rendah diperkirakan terjadi pada balok dengan retakan yang lebih dalam dan lebih lebar. Rasio kekakuan pada simpul yang lebih dekat dengan lokasi retakan diperkirakan lebih rendah dibandingkan dengan rasio pada simpul yang lebih jauh. Setelah melakukan studi parametrik, total sembilan simpul diperlukan untuk memberikan kinerja komputasi yang optimal.

Beralih ke analisis 3D, balok-T beton bertulang konvensional dimodelkan. Model balok ini terdiri dari bagian padat 3D dan dijalin dengan elemen tetrahedral kuadratik 10-simpul (C3D10) menggunakan teknik penjalinan otomatis. Tulangan dimodelkan menggunakan potongan kawat 3D yang dijalin dengan elemen rangka 3 titik simpul (T3D3), dan tiga batang tulangan dengan jarak yang sama ditanamkan pada semua model balok beton dengan ikatan antiselip yang sempurna antara beton dan batang tulangan. Gambar 13.9 dan 13.10 menunjukkan tampilan 3D ABAQUS dari sampel balok-T beton bertulang. Tulangan terdapat pada balok sampel tetapi tidak tergambar dalam gambar-gambar ini.

Asumsi model elastis linier yang sama yang dibuat untuk analisis 2D digunakan untuk analisis 3D. Untuk menentukan ukuran mata jaring optimal untuk model 3D, analisis sensitivitas mata jaring dilakukan. Hasil lendutan tengah bentang untuk balok-T 3D sampel yang tidak retak di bawah beban konstan dengan ukuran mata jaring berkisar antara 50 mm–25 mm diplot pada Gambar 13.11. Contoh waktu analisis ABAQUS untuk balok dengan ukuran mata jaring 48 mm, 35 mm, dan 26 mm masing-masing adalah 0:40, 1:00, dan 2:13 (jam: menit). Dari Gambar 13.11, variasi hasil lendutan tidak signifikan dibandingkan dengan variasi waktu analisis ABAQUS. Namun, kesalahan pemasangan mata jaring ditemukan pada balok dengan retakan kecil dengan ukuran mata jaring 50 mm. Pengujian menunjukkan bahwa frekuensi kesalahan pemasangan mata jaring berkurang seiring dengan penurunan ukuran mata jaring. Oleh karena itu, ukuran mata jaring ditetapkan sebesar 35 mm untuk elemen beton dan baja pada model balok 3D.




Gambar 13.9: Tampilan ABAQUS balok-T beton bertulang 3D yang menunjukkan lima retakan sepanjang bentang, kondisi tumpuan, dan beban yang diberikan.



Gambar 13.10: Jaring FE contoh balok-T bertulang 3D.

Untuk model 3D, sembilan simpul kekakuan disisipkan di sepanjang permukaan atas balok dengan jarak yang sama. Jumlah simpul kekakuan ini disarankan oleh analisis 2D Fase III untuk menghasilkan model kesehatan balok yang sangat akurat. Setiap simpul kekakuan dikenai beban statis secara bergantian, dan hasil lendutan pada simpul kekakuan diekstraksi dari analisis ABAQUS.



Gambar 13.11: Variasi lendutan balok dengan pengurangan ukuran jaring.

Beban diterapkan sebagai beban area pada sebagian kecil permukaan atas balok, yang berpusat pada simpul kekakuan, untuk analisis 3D. Skema konfigurasi pembebanan ini diperlukan karena penerapan beban titik untuk model balok 3D menghasilkan lendutan relatif yang sangat tinggi pada simpul kekakuan, yang menunjukkan bahwa deformasi lokal signifikan. Untuk semua model, kekakuan pada simpul tertentu diperoleh dengan membagi gaya total yang diberikan dengan lendutan pada simpul tersebut sesuai dengan Persamaan (13.16).


Sebagaimana dijelaskan sebelumnya, rasio kekakuan simpul digunakan untuk menggambarkan secara kuantitatif tingkat kerusakan lokal, atau kesehatan struktural residual, dari balok beton bertulang. Secara umum, balok dengan rasio kekakuan simpul yang rendah memiliki retakan yang dalam, lebar, atau ekstensif. Rasio kekakuan simpul di dekat retakan yang ada biasanya lebih rendah daripada rasio kekakuan simpul yang jauh dari lokasi kerusakan. Diamati bahwa retakan yang ditempatkan sangat dekat dengan tumpuan balok menghasilkan rasio kekakuan simpul yang sangat rendah dalam model 3D.

Hal ini sebagian dapat dikaitkan dengan kegagalan memenuhi prinsip Saint-Venant, yang menyatakan bahwa distribusi tegangan pada suatu material dapat diasumsikan tidak bergantung pada cara penerapan beban, kecuali di sekitar beban yang diberikan. Keberadaan beban yang diberikan dan diskontinuitas (retak) pada balok di dekat tumpuan kemungkinan besar menimbulkan konsentrasi tegangan dan regangan yang berkontribusi pada defleksi balok yang tidak terduga. Oleh karena itu, penempatan retak dibatasi pada 0,06–0,94 dari panjang bentang balok dalam model 3D; rentang di mana rasio kekakuan nodal umumnya diamati stabil pada nilai yang wajar. Dengan prosedur pemodelan FE yang telah ditetapkan, bagian selanjutnya akan membahas pembuatan basis data dan proses pelatihan.

13.4 PEMBUATAN BASIS DATA DAN IMPLEMENTASI AI

Basis Data Analisis 2D

Balok beton dengan parameter berbeda dimodelkan untuk menghasilkan basis data kerusakan analisis 2D. Parameter ini meliputi parameter geometri seperti lebar penampang (b), kedalaman penampang (d), dan panjang bentang balok (L), parameter material yang direpresentasikan oleh kuat tekan beton (f'_c), dan parameter retak meliputi kedalaman (d_{cr}), lebar (w_{cr}), dan lokasi (b_{cr}) retakan. Sebagian besar parameter dinormalisasi sehingga basis data dapat digeneralisasikan ke balok yang tidak termasuk dalam studi ini tetapi berada dalam rentang data model yang dinormalisasi.



Gambar 13.12 Tampak elevasi balok beton sampel dengan dua retakan.

Tabel 13.2: Parameter pemodelan Fase I, III (balok dengan satu retakan).

b/h	L/h	f'_c (MPa)	$d_{cr}cr/h$	w_{cr} (mm)	b_{cr}/L
0.5	7	21	0.25	0.5	0.1
0.7	10	31	0.4	1.0	0.2
0.9	13	41	0.5	2.5	0.3
–	–	–	0.75	5.0	0.4

-	-	-	-	-	0.5
---	---	---	---	---	-----

Tabel 13.3: Parameter pemodelan Fase II (balok dengan dua retakan).

b/h	L/h	f'_c (MPa)	Crack 1			Crack 2		
			d_{cr}/h	w_{cr} (mm)	b_{cr}/L	d_{cr}/h	w_{cr} (mm)	b_{cr}/L
0.5	7	21	0.25	0.5	0.167	0.25	0.5	0.667
0.7	10	31	0.50	2.5	0.333	0.50	2.5	0.833
0.9	13	41	0.75	5	0.5	0.75	5	-

Studi pemodelan 2D dilakukan dalam tiga fase. Pada fase I dan III, basis data kerusakan dihasilkan untuk balok dengan satu retakan pada paruh pertama balok. Pada fase II, basis data kerusakan dihasilkan untuk balok dengan dua retakan. Untuk mengatur kemungkinan kasus ini, bentang balok pada fase II dibagi menjadi dua wilayah. Hanya satu retakan yang mungkin terjadi di setiap wilayah, sehingga balok dapat memiliki dua, satu, atau bahkan tidak ada retakan sama sekali. Gambar 13.12 menunjukkan contoh balok dengan dua wilayah retak. Daftar parameter dan nilai terkait yang digunakan untuk menghasilkan basis data kerusakan yang disebutkan diberikan pada Tabel 13.2 dan 13.3.

Tabel 13.2 menunjukkan bahwa untuk fase I dan III, retakan dimodelkan hanya pada paruh pertama bentang balok, dengan memanfaatkan simetri distribusi retakan, yaitu balok dengan retakan yang terletak pada 0,1 L akan memiliki nilai kekakuan yang sama dengan balok dengan retakan yang sama yang terletak pada 0,9 L, kecuali bahwa urutannya akan terbalik. Hal ini dilakukan untuk meningkatkan akurasi prediksi ANN sekaligus mengurangi waktu komputasi.

Hal ini tidak berlaku pada fase II, karena retakan terdistribusi secara independen pada setiap paruh balok. Untuk fase I dan III, balok yang sehat diidentifikasi dengan memiliki rasio lokasi retakan terhadap bentang balok (b_{cr}/L) sebesar 0. Untuk fase II, balok tanpa retakan pada wilayah pertama memiliki rasio lokasi retakan terhadap bentang balok (b_{cr}/L) sebesar 0, sementara balok tanpa retakan pada wilayah kedua memiliki rasio lokasi retakan terhadap bentang balok (b_{cr}/L) sebesar 0,5. Sebagaimana telah disebutkan sebelumnya, sejumlah simpul kekakuan tertentu dimasukkan ke dalam jaring elemen hingga. Untuk fase I dan III, basis data untuk 3, 5, 7, dan 9 simpul kekakuan dihasilkan.

Dengan memanfaatkan hasil dari fase I, basis data untuk optimum hanya dihasilkan pada 9 simpul kekakuan. Sebuah makro MS Excel VBA (*Visual Basic for Applications*) ditulis untuk menghasilkan berkas masukan Abaqus (berkas *.inp) dengan memvariasikan parameter yang telah disebutkan sebelumnya untuk fase I dan II. Untuk fase III, sebuah skrip Python ditulis untuk menghasilkan berkas masukan secara langsung dengan berinteraksi dengan Abaqus.

Untuk ketiga fase tersebut, sebuah skrip Python digunakan untuk menjalankan berkas masukan yang dibuat secara batch di Abaqus, dan skrip Python lainnya ditulis untuk mengekstrak defleksi keluaran dari basis data keluaran biner Abaqus (berkas *.odb), menentukan nilai kekakuan yang sesuai dengan simpul kekakuan, menormalkannya dengan nilai kekakuan balok yang sehat, dan menyimpannya dalam basis data kekakuan. Nilai

kekakuan yang dinormalkan, atau rasio kekakuan ($k_n\%$), dihitung sebagai rasio kekakuan pada simpul balok yang retak dengan kekakuan pada simpul yang sama pada balok yang sehat. Rasio ini berfungsi sebagai indikator kerusakan balok dan dapat menunjukkan di bagian balok mana retakan tersebut berada.

Beralih ke pemodelan dan pelatihan ANN, langkah pertama adalah memberi label pada dataset dan parameter. ANN dengan rasio kekakuan ($k_n\%$) dan parameter balok (b/h , L/h , dan f'_c) sebagai masukan dan parameter retak (d_{cr}/h , w_{cr} , dan b_{cr}/L) sebagai keluaran dibuat. Ini merupakan masalah invers yang tidak memiliki solusi tunggal. Akurasi ANN diperkirakan akan meningkat seiring dengan bertambahnya jumlah simpul kekakuan. Selain itu, akurasi yang lebih baik diharapkan akan diperoleh dengan mengurangi jumlah parameter keluaran yang dibutuhkan. Masalah ini diselesaikan dalam ketiga fase. Contoh berkas header ditunjukkan pada Tabel 13.4. Input dan output diidentifikasi oleh 'I' dan 'O', masing-masing. Nilai bendera 1, 2, atau 3 menunjukkan apakah dataset digunakan dalam pelatihan, pengujian, atau validasi.

Mengikuti metodologi pemodelan ANN yang dijelaskan sebelumnya dalam bab ini, beberapa model ANN dievaluasi. Untuk semua fase, jumlah maksimum simpul tersembunyi diambil menjadi 20.

Tabel 13.4: Contoh header basis data untuk masalah invers dengan 3 simpul kekakuan dalam fase I.

b/h	L/h	f'_c (MPa)	$k_1\%$	$k_2\%$	$k_3\%$	d_{cr}/h	w_{cr} (mm)	b_{cr}/L	Flag
I	I	I	I	I	I	O	O	O	1, 2, atau 3

Tabel 13.5 Rentang normalisasi yang diperluas.

Parameter	Fase I		Fase II		Fase III	
	(Max)	(Min)	(Max)	(Min)	(Max)	(Min)
b/h	0.95	0.45	0.95	0.45	0.95	0.45
L/h	13.750	6.250	13.750	6.250	13.750	6.250
f'_c (MPa)	43.500	18.500	43.500	18.500	43.500	18.500
$k_1\%$	1.041	0.634	1.041	0.634	1.014	0.878
$k_2\%$	1.041	0.633	1.041	0.633	1.016	0.857
$k_3\%$	1.041	0.633	1.044	0.600	1.017	0.847
$k_4\%$	1.041	0.633	1.041	0.633	1.018	0.841
$k_5\%$	1.039	0.652	1.052	0.536	1.039	0.652
$k_6\%$	1.032	0.716	1.050	0.547	1.015	0.868
$k_7\%$	1.025	0.776	1.051	0.541	1.011	0.903
$k_8\%$	1.020	0.821	1.043	0.612	1.008	0.931
$k_9\%$	1.016	0.853	1.045	0.593	1.007	0.958

d_{cr}/h_1	1.000	-0.250	1.000	-0.250	1.000	-0.250
w_{cr1}	6.667	-1.667	6.667	-1.667	6.667	-1.667
b_{cr}/L_1	0.667	-0.167	0.667	-0.167	0.667	-0.167
d_{cr}/h_2	–	–	1.000	-0.250	–	–
w_{cr2}	–	–	6.667	-1.667	–	–
b_{cr}/L_2	–	–	1.111	-0.278	–	–


Selain itu, jumlah awal simpul tersembunyi diambil dari 2 menjadi 10. Pada fase I, setiap basis data kerusakan berisi 2.187 dataset yang sesuai dengan model berkas Abaqus yang dihasilkan. Dataset tersebut mencakup 27 berkas sehat, di samping 2.160 berkas rusak yang diperoleh dengan memvariasikan parameter pemodelan yang telah disebutkan sebelumnya. ANN dilatih dan diuji pada 1.093 dan 550 dataset, masing-masing, untuk mendapatkan jumlah simpul tersembunyi dan iterasi yang optimal. Set pelatihan mencakup nilai maksimum dan minimum untuk setiap parameter untuk menangkap rentang penuh dataset.

Rentang yang digunakan untuk menormalkan parameter sengaja diperluas untuk memfasilitasi pemetaan yang lebih baik. Parameter masukan dipetakan agar sesuai dengan 10%–90% dari rentang yang diperluas, sementara parameter keluaran dipetakan agar sesuai dengan 20%–80% dari rentang yang diperluas. Hal ini dilakukan agar parameter berada dalam wilayah sensitif fungsi sigmoid. Rentang yang diperluas yang digunakan pada setiap fase ditunjukkan pada Tabel 13.5. Model ANN dengan kinerja terbaik kemudian dipilih berdasarkan ukuran statistik seperti *Averaged-Squared-Error* (ASE), koefisien determinasi (R^2), dan *Mean Absolute Relative Error* (MARE), yang telah didefinisikan sebelumnya dalam bab ini.

Basis Data Analisis 3D

Basis data balok-T beton bertulang 3D dibuat dengan memvariasikan parameter geometri dan material untuk semua balok, serta parameter retak untuk balok yang retak. Parameter geometri meliputi lebar penampang badan balok (b_w), kedalaman seluruh penampang balok (h), tinggi sayap balok, atau pelat (h_s), dan panjang bentang balok (L). Sayap balok dimodelkan sesuai ketentuan *American Concrete Institute* (ACI, 318-14) Bagian 8.4.1.8 untuk pelat dua arah, yang menunjukkan bahwa lebar total sayap balok-T harus sama dengan jumlah lebar badan dan dua kali tinggi balok yang memanjang di bawah sayap seperti ditunjukkan pada Gambar 13.13 (Komite ACI 318, 2014).


Ukuran batang tulangan di setiap balok bergantung pada rasio baja (ρ) dan luas penampang balok menurut hubungan: $A_s = \rho b_w d$, di mana A_s adalah total luas penampang tulangan baja dan d adalah kedalaman efektif penampang balok, diambil sebagai kedalaman balok dikurangi selimut. Kuat tekan beton 28 hari (f_c) adalah satu-satunya parameter material variabel. Parameter retak meliputi lokasi (b_{cr}), kedalaman (d_{cr}), dan lebar (w_{cr}) setiap retak, dan semua lokasi retak diukur dari tumpuan balok yang konstan (kiri). Kecuali untuk f_c , ρ , dan w_{cr} , semua parameter dinormalisasi langsung terhadap lebar badan balok $b_w = 250 \text{ mm}$ (9,8 in), menghasilkan parameter ternormalisasi b_w/h , h_s/h , L/h , b_{cr}/L , dan d_{cr}/h .



Gambar 13.13: Dimensi balok-T.

Normalisasi ini dilakukan agar hasil studi ini dapat diaplikasikan pada balok dengan berbagai ukuran. Tinggi pelat juga diatur agar tetap konstan pada $h_s = 100$ mm (3,9 inci) untuk membatasi jumlah balok yang dihasilkan melalui variasi parametrik, meskipun parameter h_s/h yang dinormalisasi berfluktuasi karena variabilitas kedalaman balok. Gambar 13.14 menampilkan tampilan elevasi balok dengan dua retakan dan menyoroti beberapa dimensi sifat geometris dan semua lokasi simpul kekakuan.

Semua balok dibagi menjadi lima segmen yang sama yang masing-masing dapat berisi hingga satu retakan. Tujuh puluh dua balok yang sehat pertama kali dibuat untuk memberikan hasil referensi untuk perhitungan rasio kekakuan nodal untuk balok yang retak. Sebagian besar basis data balok terdiri dari balok dengan satu retakan; total 6.624 balok yang retak tunggal dimodelkan. Balok-balok ini diizinkan memiliki retakan di segmen mana pun, dan lokasi retakan divariasikan antara awal, tengah, dan akhir setiap segmen.



Gambar 13.14: Tampilan elevasi balok-T beton bertulang 3D.

Tabel 13.6: Variabilitas parameter untuk input.

Parameter	Nilai-nilai								
b_n/h	0.5	0.7	0.9						
L/h	7	10	13						
ρ	0.005	0.01							
f_c MPa (ksi)	20 (2.9)		30 (4.35)			40 (5.8)		50 (7.25)	
$K\%_n$	$K\%_1$	$K\%_2$	$K\%_3$	$K\%_4$	$K\%_5$	$K\%_6$	$K\%_7$	$K\%_8$	$K\%_9$

Balok yang jauh lebih sedikit (3.600) dengan lima retakan dihasilkan. Dua konfigurasi lokasi retakan diizinkan untuk balok-balok ini, dan lokasi retakan ditetapkan di tengah setiap segmen.

Konfigurasi lokasi retakan didefinisikan sebagai kombinasi unik dari segmen yang retak dan nilai b_{cr}/L . Hanya 384 balok dengan dua retakan, 448 balok dengan tiga retakan, dan 320 balok dengan empat retakan yang dibuat dan retakan ada di atau hilang dari masing-masing dari lima segmen. Dengan mengekspos ANN ke sejumlah besar data untuk balok dengan retakan tunggal dengan data sampel untuk balok dengan dua dan lima retakan, jaringan saraf tiruan diharapkan dapat memberikan prediksi kerusakan yang cukup akurat untuk balok dengan 0–5 retakan dalam konfigurasi apa pun.

Satu ANN dilatih untuk mengembangkan model deteksi kerusakan struktural untuk balok-T beton bertulang 3D. Jaringan dilatih dengan parameter geometri, material, dan kekakuan (b_w/h , h_s/h , L/h , ρ , f'_c , $k\%$, dengan n^{th} adalah simpul kekakuan ke- n^{th} pada sembilan simpul kekakuan yang berjarak sama) sebagai masukan, lihat Tabel 13.6, dan parameter retakan ($b_{cr,m}/L$, $d_{cr,m}/h$, dan $w_{cr,m}$, dengan m menunjukkan retakan ke- m^{th}) sebagai keluaran.

Lembar kerja Microsoft Excel digunakan untuk memelihara basis data balok dan memformat kumpulan data untuk analisis ANN. Selain 14 parameter masukan kekakuan geometrik, material, dan nodal serta lima belas parameter retak, lembar kerja tersebut juga berisi nomor identifikasi (ID) dan pengenal set (Set). Nomor identifikasi berfungsi sebagai istilah yang digunakan untuk mereferensikan balok antara lembar kerja dan ANN. Pengenal set memiliki nilai 1, 2, atau 3, dan menunjukkan apakah data balok digunakan untuk pelatihan, pengujian, atau validasi ANN.

Pengenal ini ditetapkan secara manual secara semi-acak, tetapi beberapa balok dengan parameter yang memiliki nilai ekstrem ditetapkan ke kumpulan data pelatihan. Selain itu, menurut prosedur ini, 50%, 25%, dan 25% dari kumpulan data balok unik asli ditetapkan ke kumpulan pelatihan, pengujian, dan validasi, masing-masing. Tabel 13.7 menampilkan contoh header untuk lembar kerja Microsoft Excel, di mana 'I' menunjukkan parameter masukan, 'O' menunjukkan parameter keluaran, 'm' menunjukkan retak ke- m^{th} , dan 'n' menunjukkan simpul kekakuan ke- n^{th} .

Tabel 13.7: Contoh tajuk basis data Microsoft Excel untuk masalah deteksi kerusakan.

ID	b_w/h	h_s/h	L/h	ρ	f'_c (MPa)	$k\%$	$b_{cr,m}/L$	$d_{cr,m}/h$	$w_{cr,m}$ (mm)	set
#	I	I	I	I	I	I	O	O	O	1, 2, atau 3

Basis data balok beton bertulang final berisi data untuk 42.804 balok. Sebanyak 37.116 balok (5.688 balok asli dan 31.428 balok duplikat dengan mencerminkan lokasi, kedalaman, dan lebar retakan) digunakan untuk pelatihan. Di sisi lain, separuh dari jumlah balok asli (2.844 balok) digunakan dalam setiap pengujian dan validasi ANN. Rentang nilai parameter minimum dan maksimum yang diberikan ke ANN diperluas untuk menjaga nilai parameter aktual tetap berada dalam wilayah sensitif fungsi aktivasi sigmoid jaringan.

Rentang parameter masukan diperluas agar parameter masukan berada dalam kisaran 10%–90% dari rentang yang diperluas. Rasio kekakuan nodal dibatasi pada balok sehat ($\leq 1,0$), sehingga rentang parameter keluaran diperluas sehingga hanya nilai minimum yang dimodifikasi, dan parameter keluaran berada dalam kisaran 20%–100% dari rentang yang diperluas. Rentang parameter yang diperluas ditampilkan pada Tabel 13.8.

Tabel 13.8: Rentang parameter ANN yang diperluas untuk masalah deteksi kerusakan pada Analisis 3D.

Input			Output		
Parameter	Minimum	Maksimum	Parameter	Minimum	Maksimum
bw/h	0.45	0.95	bcr1/L	0.013	0.247
h/h	0.18	0.38	dcr1/h	0.000	0.852
L/h	6.25	13.75	wcr1	0.000	6.667
P	0.00	0.01	bcr2/L	0.133	0.467
fc'MPa (ksi)	16.25 (2.35)	53.75 (7.79)	dcr2/h	0.000	0.852
k%1	0.635	1.00	wcr2	0.000	6.667
k%2	0.509	1.00	bcr3/L	0.333	0.667
k%3	0.477	1.00	dcr3/h	0.000	0.852
k%4	0.434	1.00	wcr3	0.000	6.667
k%5	0.412	1.00	bcr4/L	0.533	0.867
k%6	0.432	1.00	dcr4/h	0.000	0.852
k%7	0.483	1.00	wcr4	0.000	6.667
k%8	0.512	1.00	bcr5/L	0.753	0.987
k%9	0.639	1.00	dcr5/h	0.000	0.852
			wcr5	0.000	6.667

13.5 PEMODELAN AI PADA BASIS DATA

Beberapa jaringan dibuat untuk setiap basis data mengikuti metodologi yang telah dijelaskan sebelumnya. Setiap jaringan memiliki parameter geometri dan material balok (b/h, L/h, dan $f'c$) serta rasio kekakuan (kn%) sebagai masukan, sedangkan parameter retak (dcr/h, wcr, dan bcr/L) merupakan keluaran yang dibutuhkan. Dari proses pelatihan, pengujian, dan validasi, diperoleh struktur ANN yang optimal untuk setiap basis data kerusakan. Dimulai dengan fase I, untuk basis data dengan 3 simpul kekakuan, nilai MARE dan ASE minimum serta nilai R2 maksimum diperoleh dengan 19 simpul tersembunyi pada 18.200 iterasi.

Demikian pula, struktur optimal diperoleh dengan 18 simpul tersembunyi pada 20.000 iterasi, 8 simpul tersembunyi pada 18.100 iterasi, dan 11 simpul tersembunyi pada 20.000 iterasi untuk basis data simpul kekakuan 5, 7, dan 9. Diamati bahwa, secara umum, jumlah simpul tersembunyi menurun seiring dengan peningkatan jumlah simpul kekakuan. Tampaknya menyediakan ANN dengan lebih banyak input mengurangi kebutuhan akan lebih banyak simpul tersembunyi untuk aplikasi ini. Efek ini diinginkan karena mengurangi jumlah

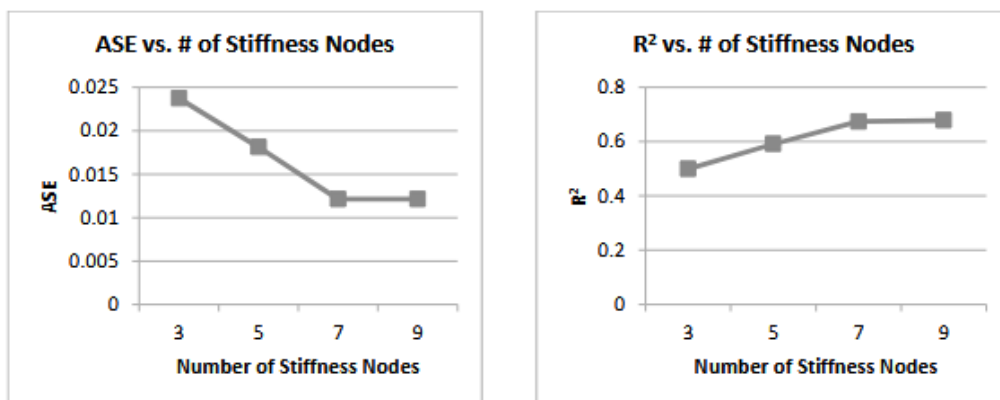
simpul tersembunyi mengurangi kompleksitas ANN dan menurunkan kemungkinan terjadinya kelainan untuk prediksi yang berbeda.

Tabel 13.9 menunjukkan model terbaik yang diperoleh untuk setiap basis data dalam fase I dan statistiknya setelah pelatihan pada semua set data. Selain itu, Gambar 13.15(a) dan (b) menunjukkan bagaimana ASE dan R², masing-masing, bervariasi dengan peningkatan jumlah simpul kekakuan. Seperti yang diharapkan, tren yang tercatat menunjukkan peningkatan akurasi prediksi ANN seiring bertambahnya jumlah simpul kekakuan, dengan laju perubahan kesalahan stabil pada 9 simpul kekakuan. Statistik untuk pelatihan, pengujian, validasi, dan pelatihan pada semua set data untuk 9 ANN simpul kekakuan dirangkum dalam Tabel 13.10. Dari pelatihan dan pengujian, struktur jaringan optimal yang diperoleh adalah 9, 11, dan 9 simpul tersembunyi lagi, semuanya pada 20.000 iterasi. Model 1 dan 2 memberikan hasil yang lebih baik daripada model 3 dalam validasi. Akhirnya, model 2 dipilih karena memberikan hasil yang serupa dengan model 1 dalam validasi dan hasil yang lebih baik setelah pelatihan pada semua set data.

Beralih ke fase II, ANN dibuat untuk memecahkan masalah invers deteksi kerusakan untuk balok dengan dua retakan yang dimodelkan menggunakan elemen balok mengikuti metodologi yang dijelaskan sebelumnya. ANN ini dilatih, diuji, dan divalidasi pada basis data 9 simpul kekakuan yang dihasilkan. Untuk fase ini, masukannya adalah parameter geometri dan material balok (b/h , L/h , dan $f'c$) di samping rasio kekakuan ($kn\%$), sedangkan keluarannya adalah dua parameter retakan ($dcr/h1$, $wcr1$, $bcr/L1$, $dcr/h2$, $wcr2$, dan $bcr/L2$). Tabel 13.11 menunjukkan dua model terbaik yang diperoleh pada fase II dan statistik detailnya untuk pelatihan, pengujian, validasi, dan pelatihan pada semua set data.

Tabel 13.9: Hasil ANN masalah invers pada fase I.

# Kekakuan Node	Model (INP-HN-OUT)	Iterasi	MARE (%)	R2R2	ASE
3	6-19-3	18200	69.919	0.499	0.024
5	8-18-3	20000	64.681	0.592	0.018
7	10-8-3	18100	52.858	0.674	0.012
9	12-11-3	20000	52.338	0.678	0.012



Gambar 13.15: (a) Kurva ASE vs. jumlah simpul kekakuan (b) Kurva R² vs. jumlah simpul kekakuan untuk fase I.

Tabel 13.10: Hasil terperinci ANN masalah invers dalam fase I (9 simpul kekakuan).

	Model 1 12_(4-9_20000)_3	Model 2 12_(5-11_20000)_3	Model 3 12_(6-9_20000)_3
Pelatihan (Training)			
MARE %	52,065	51,835	53,166
R ²	0,677	0,682	0,666
ASE	0,012	0,012	0,012
Pengujian (Testing)			
MARE %	53,879	53,432	54,414
R ²	0,679	0,671	0,672
ASE	0,012	0,012	0,012
Validasi			
MARE %	48,081	48,084	49,089
R ²	0,680	0,678	0,672
ASE	0,012	0,012	0,012
Seluruh Data			
MARE %	52,583	52,338	54,273
R ²	0,661	0,678	0,665
ASE	0,012	0,012	0,013

Tabel 13.11: Hasil terperinci ANN masalah invers pada fase II.

	Model 1 12_(4-18_20000)_6	Model 2 12_(5-16_20000)_6
Pelatihan (Training)		
MARE %	88,174	89,314
R ²	0,609	0,580
ASE	0,022	0,023
Pengujian (Testing)		
MARE %	87,913	88,936
R ²	0,607	0,579
ASE	0,022	0,024
Validasi		
MARE %	85,971	86,963
R ²	0,603	0,575
ASE	0,023	0,024
Seluruh Data		
MARE %	84,568	88,522
R ²	0,652	0,610
ASE	0,018	0,024

Dari pelatihan dan pengujian, struktur optimal yang diperoleh adalah 18 simpul tersembunyi pada model 1 dan 16 simpul tersembunyi pada model 2, keduanya diperoleh pada 20.000 iterasi. Selanjutnya, validasi dilakukan dan model 1 memberikan nilai MARE dan ASE terendah serta nilai R² tertinggi, sehingga terpilih sebagai model terbaik. Model 1 juga memberikan statistik yang lebih baik ketika dilatih pada semua set data.

Penurunan kecil dalam akurasi permasalahan invers pada ANN terjadi pada fase II. Nilai statistik untuk ANN II adalah MARE = 84,568%, R² = 0,65207, dan ASE = 0,01812, dibandingkan dengan ANNi-1, dengan MARE = 52,338%, R² = 0,67834, dan ASE = 0,012113 pada fase I. Perbedaan persentase dari ANNi-1 ke ANN II masing-masing adalah 61,58%, -3,87%, dan 49,59% untuk MARE, R², dan ASE. Penurunan ini diperkirakan karena ANN mencoba memprediksi tiga keluaran tambahan pada fase II dibandingkan dengan fase I. Meskipun galat

yang diperoleh relatif tinggi, prediksi ANN ini masih dapat dianggap wajar untuk aplikasi praktis.

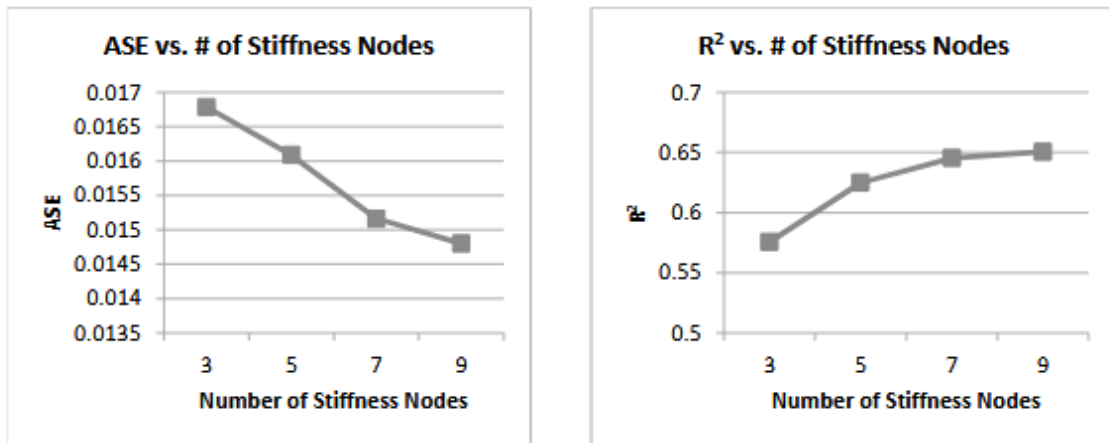
Hal ini dikarenakan parameter retak sangat kecil, sehingga nilai galat yang besar sekalipun hanya dapat menyebabkan variasi dalam fraksi milimeter, terutama pada lebar retak. Akhirnya, pada fase III, JST dibuat untuk memecahkan masalah invers deteksi kerusakan untuk balok dengan retak tunggal yang dimodelkan menggunakan FE tegangan bidang mengikuti metodologi yang dijelaskan sebelumnya. Untuk fase ini, masukannya adalah parameter geometri dan material balok (b/h , L/h , dan f'_c) di samping rasio kekakuan ($kn\%$), sedangkan keluarannya adalah parameter retak (d_{cr}/h , w_{cr} , dan b_{cr}/L). JST ini dilatih, diuji, dan divalidasi pada basis data 3, 5, 7, dan 9 simpul kekakuan yang dihasilkan.

Dari pelatihan dan pengujian, struktur optimal yang diperoleh adalah 12 simpul tersembunyi pada 20.000 iterasi, 9 simpul tersembunyi pada 4.100 iterasi, 10 simpul tersembunyi pada 11.200 iterasi, dan 9 simpul tersembunyi pada 19.600 iterasi untuk basis data 3, 5, 7, dan 9 simpul kekakuan, masing-masing. Dibandingkan dengan jaringan yang diperoleh pada fase I, JST yang diperoleh pada fase III umumnya memiliki lebih sedikit simpul tersembunyi, terutama untuk jaringan dengan jumlah simpul kekakuan yang lebih sedikit. Hal ini semakin memperkuat implikasi bahwa kualitas dataset dalam basis data kerusakan pada fase III lebih tinggi. Tabel 13.12 menunjukkan model terbaik yang diperoleh untuk setiap basis data pada fase III dan statistiknya setelah pelatihan pada semua dataset.

Selain itu, Gambar 13.16(a) dan (b) menunjukkan bagaimana ASE dan R^2 , masing-masing, bervariasi dengan peningkatan jumlah simpul kekakuan. Seperti yang diharapkan, tren yang dicatat menunjukkan peningkatan akurasi prediksi JST seiring dengan peningkatan jumlah simpul kekakuan. Statistik untuk pelatihan, pengujian validasi, dan pelatihan pada semua dataset untuk 9 JST simpul kekakuan dirangkum dalam Tabel 13.13. Dari pelatihan dan pengujian, struktur jaringan optimal yang diperoleh adalah 9 simpul tersembunyi pada 19.600 iterasi, 7 simpul tersembunyi pada 7.100 iterasi, dan 7 simpul tersembunyi lagi pada 19.100 iterasi. Model 1 dipilih karena memberikan hasil yang lebih baik daripada model 2 dan 3 di semua tahap pemodelan, termasuk pelatihan pada semua set data.

Tabel 13.12: Hasil ANN masalah invers pada fase III.

Jumlah Node Kekakuan	Model (INP-HN-OUT)	Iterasi	MARE (%)	R^2	ASE
3	6-12-3	20.000	63,645	0,576	0,017
5	8-9-3	4.100	67,240	0,625	0,016
7	10-10-3	11.200	62,514	0,645	0,015
9	12-9-3	19.600	60,693	0,651	0,015



Gambar 13.16: (a) Kurva ASE vs. jumlah simpul kekakuan (b) Kurva R2 vs. jumlah simpul kekakuan untuk fase III.

Tabel 13.13: Hasil rinci ANN masalah invers pada fase III (9 node kekakuan).

	Model 1 12_(5-9_19600)_3	Model 2 12_(3-7_7100)_3	Model 3 12_(4-7_19100)_3
Pelatihan (Training)			
MARE %	60,801	62,040	62,711
R ²	0,655	0,645	0,640
ASE	0,015	0,015	0,015
Pengujian (Testing)			
MARE %	57,994	58,468	58,788
R ²	0,633	0,627	0,631
ASE	0,016	0,016	0,016
Validasi			
MARE %	58,779	59,159	59,756
R ²	0,634	0,625	0,626
ASE	0,015	0,015	0,015
Seluruh Data			
MARE %	60,693	63,941	60,966
R ²	0,651	0,640	0,642
ASE	0,015	0,015	0,015

Pemodelan AI pada Basis Data Analisis 3D

Program ANN dengan satu lapisan tersembunyi digunakan dalam studi ini, dan jumlah awal simpul tersembunyi ditetapkan bervariasi antara 2 dan 10. Meskipun jumlah maksimum simpul tersembunyi yang dihitung melebihi 270, penggunaan 20 simpul tersembunyi sebagai jumlah maksimum terbukti cukup memfasilitasi pembelajaran dalam jaringan saraf tiruan. Selain mengurangi waktu proses program, penggunaan simpul tersembunyi yang lebih sedikit daripada jumlah maksimum yang dihitung membantu ANN menghindari hafalan.

Set data pelatihan dan pengujian digunakan untuk melatih sembilan arsitektur jaringan, masing-masing sesuai dengan jumlah simpul tersembunyi awal yang berbeda. ANN pertama-tama dievaluasi berdasarkan ASE (kesalahan kuadrat rata-rata) dan R² (koefisien determinasi). Jumlah simpul tersembunyi awal dan akhir yang optimal serta jumlah iterasi pada jumlah simpul tersembunyi akhir dicatat untuk tiga jaringan yang paling efektif dalam hal

kinerja pengukuran statistiknya. Jaringan optimal ini kemudian diuji menggunakan set data validasi dan dilatih pada seluruh basis data balok-T beton bertulang untuk mengeksposnya ke semua data yang tersedia dan membangun model deteksi kerusakan struktural yang robust. Tabel 13.14 menyajikan hasil statistik untuk model optimal yang digunakan selama pemilihan struktur jaringan akhir untuk aplikasi prediksi deteksi kerusakan.

Tabel 13.14: Hasil statistik untuk parameter prediksi retak ANN optimal dari Analisis 3D

	Model 1 (4-15-2000)	Model 2 (8-10-2000)	Model 3 (9-16-18900)
Pelatihan (Training)			
R ²	0,405	0,365	0,422
ASE	0,046	0,050	0,041
Pengujian (Testing)			
R ²	0,377	0,289	0,422
ASE	0,043	0,044	0,032
Validasi			
R ²	0,365	0,298	0,404
ASE	0,046	0,049	0,035
Seluruh Data			
R ²	0,391	0,351	0,426
ASE	0,045	0,049	0,040

Demikian pula, proses pelatihan ANN dan prosedur pemilihan model optimal diterapkan pada basis data model balok beton bertulang FE untuk membangun model prediksi deteksi kerusakan. Identifikasi model didasarkan pada nomenklatur berikut: jumlah awal simpul tersembunyi - jumlah akhir simpul tersembunyi - iterasi pada jumlah akhir simpul tersembunyi. Hasil statistik dari fase pelatihan dan pengujian awal mengungkapkan arsitektur jaringan berkinerja terbaik adalah model 4-15-2000, 8-10-2000, dan 9-16-18900. ANN ini kemudian diuji pada set validasi dan dilatih pada seluruh basis data (semua data). Hasil statistik terperinci untuk jaringan optimal ini ditampilkan pada Tabel 13.14.

Beberapa observasi dan tren umum terlihat jelas pada Tabel 13.14. Pertama dan terpenting, jaringan menunjukkan akurasi prediksi yang lemah dengan kesalahan kuadrat (ASE) yang tinggi di semua fase dan koefisien determinasi (R²) yang melebihi 0,42 untuk semua analisis data. Seperti yang diharapkan, jaringan deteksi kerusakan, yang memprediksi 15 variabel yang tidak diketahui, berkinerja cukup baik menurut ukuran statistik karena sifat masalah yang tidak unik.

Selain itu, rongga dalam kumpulan data yang ditetapkan berdasarkan balok dengan dua, tiga, dan empat retakan yang hilang diperkirakan akan sedikit menurunkan ukuran statistik model ANN. Memperkaya basis data dengan informasi tambahan, yang sangat memakan waktu, diperkirakan akan sedikit meningkatkan ukuran statistik yang dihasilkan. Namun demikian, ukuran-ukuran ini diperkirakan akan tetap relatif sederhana karena kurangnya keunikan proses prediksi kerusakan.

Contoh Analisis 2D

Dua contoh untuk setiap fase diberikan di bawah ini untuk mengilustrasikan penerapan pendekatan sinergi AI-FE yang dikembangkan dalam bab ini. Salah satu kasus contoh merupakan bagian dari kumpulan data yang digunakan untuk melatih ANN, sedangkan kasus kedua adalah untuk balok yang dihasilkan menggunakan analisis elemen hingga yang belum pernah dialami jaringan sebelumnya. Lihat Tabel 13.15–13.21 untuk parameter masukan dan keluaran yang diperoleh dari model ANN untuk fase I, II, dan III.

Tabel 13.15: Parameter masukan untuk contoh balok untuk fase I.

ID	b/h	L/h	f _c (MPa)	k ₁ (%)	k ₂ (%)	k ₃ (%)	k ₄ (%)	k ₅ (%)	k ₆ (%)	k ₇ (%)	k ₈ (%)	k ₉ (%)
B1	0,7	13	21	0,961	0,990	0,996	0,998	0,998	0,999	0,999	0,999	1,000
B2	0,6	12	35	0,997	0,996	0,997	0,998	0,999	0,999	0,999	1,000	1,000

Tabel 13.16: Contoh prediksi balok yang diperoleh untuk fase I.

ID	Aktual			Prediksi dengan ANN1			Prediksi dengan ANN8, 9, 10		
	d _{cr} /h	w _{cr} (mm)	b _{cr} /L	d _{cr} /h	w _{cr} (mm)	b _{cr} /L	d _{cr} /h	w _{cr} (mm)	b _{cr} /L
B1	0,75	1,00	0,10	0,714	1,239	0,108	0,701	0,860	0,099
B2	0,45	2,00	0,25	0,426	2,480	0,252	0,400	2,458	0,215

Tabel 13.17: Parameter geometri, material, dan retak untuk contoh balok untuk fase II.

ID	b/h	L/h	f _c (MPa)	d _{cr} /h ¹	w _{cr} (mm) ¹	b _{cr} /L ¹	d _{cr} /h ²	w _{cr} (mm) ²	b _{cr} /L ²
B1	0,9	7	21	0,25	2,5	0,333	0,75	5	0,667
B2	0,7143	10	28	0,55	4	0,22	0,22	2	0,68

Tabel 13.18: Rasio kekakuan untuk balok contoh untuk fase II.

ID	k ₁ (%)	k ₂ (%)	k ₃ (%)	k ₄ (%)	k ₅ (%)	k ₆ (%)	k ₇ (%)	k ₈ (%)	k ₉ (%)
B1	0,935	0,919	0,897	0,867	0,821	0,747	0,694	0,747	0,789
B2	0,968	0,960	0,959	0,952	0,936	0,906	0,868	0,896	0,916

Tabel 13.19: Prediksi balok contoh yang diperoleh untuk masalah invers pada fase II.

ID	Crack	Aktual			Diprediksi		
		d _{cr} /h	w _{cr} /mm	b _{cr} /L	d _{cr} /h	w _{cr} (mm)	b _{cr} /L
B1	1	0,25	2,5	0,333	0,232	2,357	0,328
	2	0,75	5	0,667	0,671	5,160	0,681
B2	1	0,55	4	0,22	0,243	3,87	0,154
	2	0,22	2	0,68	0,723	2,835	

Tabel 13.20: Parameter masukan untuk contoh balok untuk fase III.

ID	b/h	L/h	f _c (MPa)	k ₁ (%)	k ₂ (%)	k ₃ (%)	k ₄ (%)	k ₅ (%)	k ₆ (%)	k ₇ (%)	k ₈ (%)	k ₉ (%)
B1	0.9	10	21	0.946	0.926	0.961	0.977	0.985	0.990	0.993	0.995	0.997
B2	0.65	11	28	0.970	0.957	0.943	0.947	0.965	0.976	0.982	0.987	0.991

Tabel 13.21: Contoh prediksi balok yang diperoleh untuk fase III.

ID	Aktual			Diprediksi		
	d_{cr}/h	$w_{cr}(mm)$	b_{cr}/L	d_{cr}/h	$w_{cr}(mm)$	b_{cr}/L
B1	0,5	2,5	0,2	0,499	2,118	0,208
B2	0,75	3	0,35	0,684	2,162	0,340

Contoh Analisis 3D

Dua contoh diberikan di bawah ini untuk mengilustrasikan aplikasi ANN yang dikembangkan dalam analisis ini. Contoh pertama adalah balok yang termasuk dalam kumpulan data yang digunakan dalam pengembangan ANN. Contoh kedua adalah balok yang sebelumnya tidak terekspos ke jaringan. Parameter balok pertama adalah: $b = 250$ mm, $h = 500$ mm, $L = 3500$ mm, dan $f'_c/L = 20$ MPa. Parameter geometri balok yang dinormalisasi dan rasio kekakuan yang diperoleh ditunjukkan pada Tabel 13.22.

Model ANN yang dikembangkan digunakan untuk memprediksi parameter retak dan hasilnya ditunjukkan pada Tabel 13.23. Balok aktual mengandung dua retakan pada sepertiga pertama balok, parameter retakan pertama adalah $d_{cr}/h = 0,639$, $w_{cr} = 5$ mm, dan $b_{cr}/L = 0,1$, sedangkan parameter retakan kedua adalah $d_{cr}/h = 0,1$, $w_{cr} = 0,05$ mm, dan $b_{cr}/L = 0,3$. Parameter yang diprediksi untuk retakan pertama adalah $d_{cr}/h = 0,705$, $w_{cr} = 2,88$ mm, dan $b_{cr}/L = 0,114$ dan untuk retakan kedua adalah $d_{cr}/h = 0,149$, $w_{cr} = 1,58$ mm, dan $b_{cr}/L = 0,338$. ANN memprediksi retakan kecil tambahan pada $b_{cr}/L = 0,87$ dengan d_{cr}/h kecil = 0,01, dan $w_{cr} = 0,056$ mm. Retak ketiga yang diprediksi merupakan akibat langsung dari sifat non-unik dari masalah invers. Parameter balok kedua adalah: $b = 250$ mm, $h = 332$ mm, $L = 3863,6$ mm, dan $f'_c = 43,16$ MPa. Parameter geometri balok yang dinormalisasi dan rasio kekakuan yang diperoleh ditunjukkan pada Tabel 13.22.

Model ANN yang dikembangkan digunakan untuk memprediksi parameter retak dan hasilnya ditunjukkan pada Tabel 13.23. Balok aktual mengandung tiga retakan pada separuh terakhir balok, parameter retakan pertama adalah $d_{cr}/L = 0,5$, $w_{cr} = 1,3$ mm, dan $b_{cr}/L = 0,6$, sedangkan parameter retakan kedua adalah $d_{cr}/L = 0,56$, $w_{cr} = 3,2$ mm, dan $b_{cr}/L = 0,64$, dan parameter retakan ketiga adalah $w_{cr} = 0,029$, $w_{cr} = 0,54$ mm, dan $b_{cr}/L = 0,8$. ANN memprediksi empat retakan: retakan minor dengan $d_{cr}/L = 0,018$ pada $b_{cr}/L = 0,076$ dan tiga retakan mayor pada separuh terakhir balok. ANN berhasil memprediksi secara tepat lokasi dan kedalaman retakan kedua dari retakan mayor, sementara memperkirakan lokasi dua retakan mayor lainnya dengan kesalahan 10%. Meskipun keseluruhan pengukuran statistik ANN menunjukkan kesalahan yang relatif tinggi, hasil yang diperoleh di sini cukup masuk akal terkait lokasi dan kedalaman retakan dan menunjukkan kesesuaian yang baik dengan data aktual.

Tabel 13.22: Contoh parameter balok.

ID	b/h	L/h	f'_c (MPa)	k_1 (%)	k_2 (%)	k_3 (%)	k_4 (%)	k_5 (%)	k_6 (%)	k_7 (%)	k_8 (%)	k_9 (%)
B2C1	0,5	7	20	0,905	0,918	0,945	0,964	0,976	0,984	0,989	0,992	0,996
B3CT	0,753	11,64	43,16	0,957	0,939	0,919	0,892	0,852	0,794	0,809	0,851	0,892

Tabel 13.23: Contoh hasil balok.

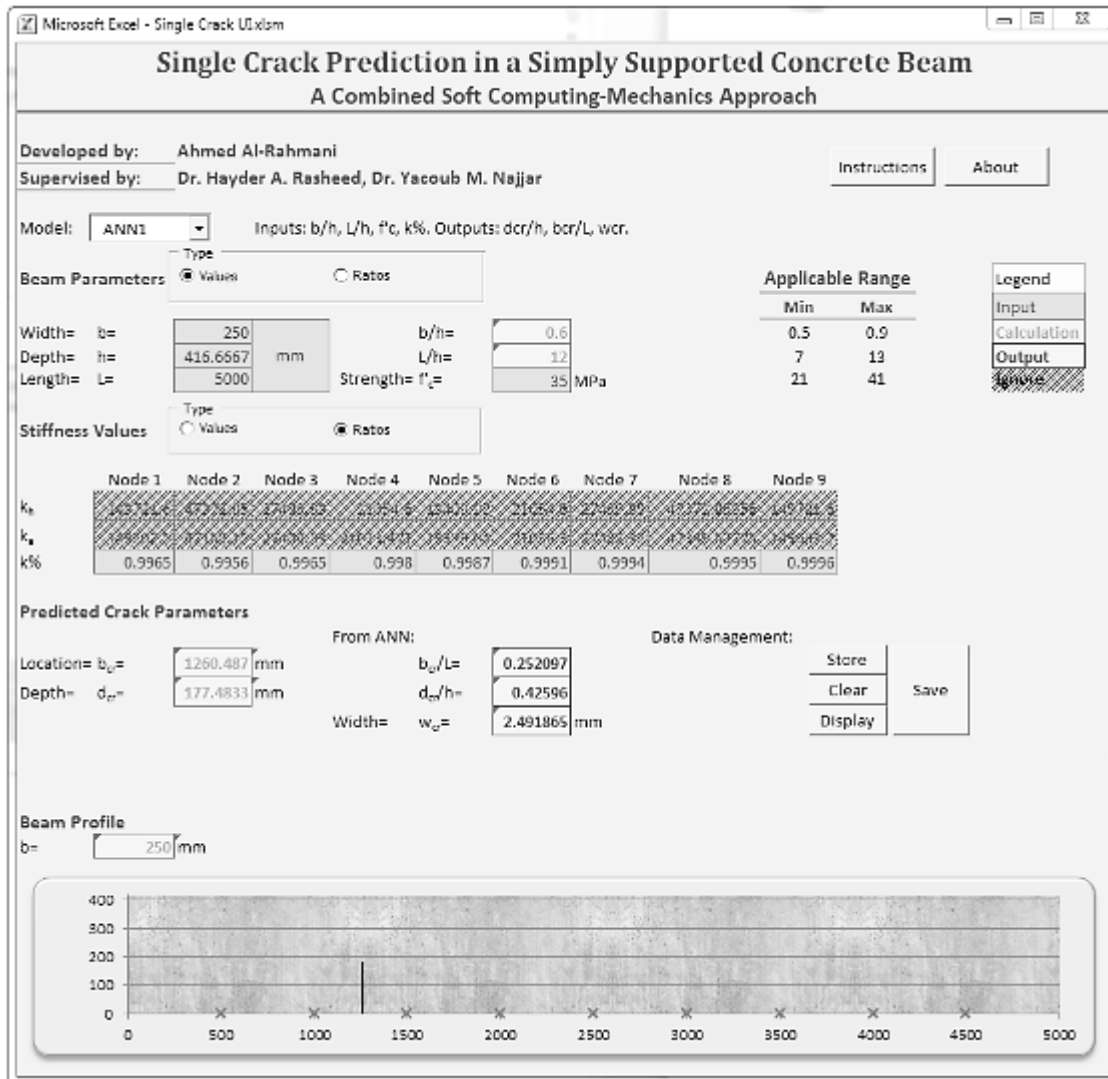
ID	Aktual			Prediksi		
	d_{cr}/h	$w_{cr}(mm)$	b_{cr}/L	d_{cr}/h	$w_{cr}(mm)$	b_{cr}/L
Balok Pertama						
Retak Pertama	0.639	5	0.1	0.705	2.88	0.114
Retak Kedua	0.1	0.05	0.3	0.149	1.58	0.338
Retak Ketiga	0	0	0	0.01	0.056	0.87
Balok Kedua						
Retak Pertama	0	0	0	0.018	0.44	0.076
Retak Kedua	0.5	1.3	0.6	0.32	1.73	0.48
Retak Ketiga	0.565	3.2	0.64	0.54	2.53	0.65
Retak Keempat	0.029	0.543	0.8	0.5	2.4	0.9

Antarmuka Perangkat Lunak Analisis 2D

Setelah menyelesaikan pelatihan, pengujian, validasi, dan akhirnya pelatihan pada semua set data, model ANN yang optimal diperoleh. Model ANN ini terdiri dari simpul, ambang batasnya, dan bobot koneksi di antara keduanya. Untuk memfasilitasi evaluasi dan deteksi kerusakan menggunakan model ANN yang telah dikembangkan, antarmuka Excel telah dibuat. Antarmuka ini dibuat menggunakan Microsoft Excel 2010 dan kode Visual Basic for Application (VBA) digunakan untuk backend-nya.

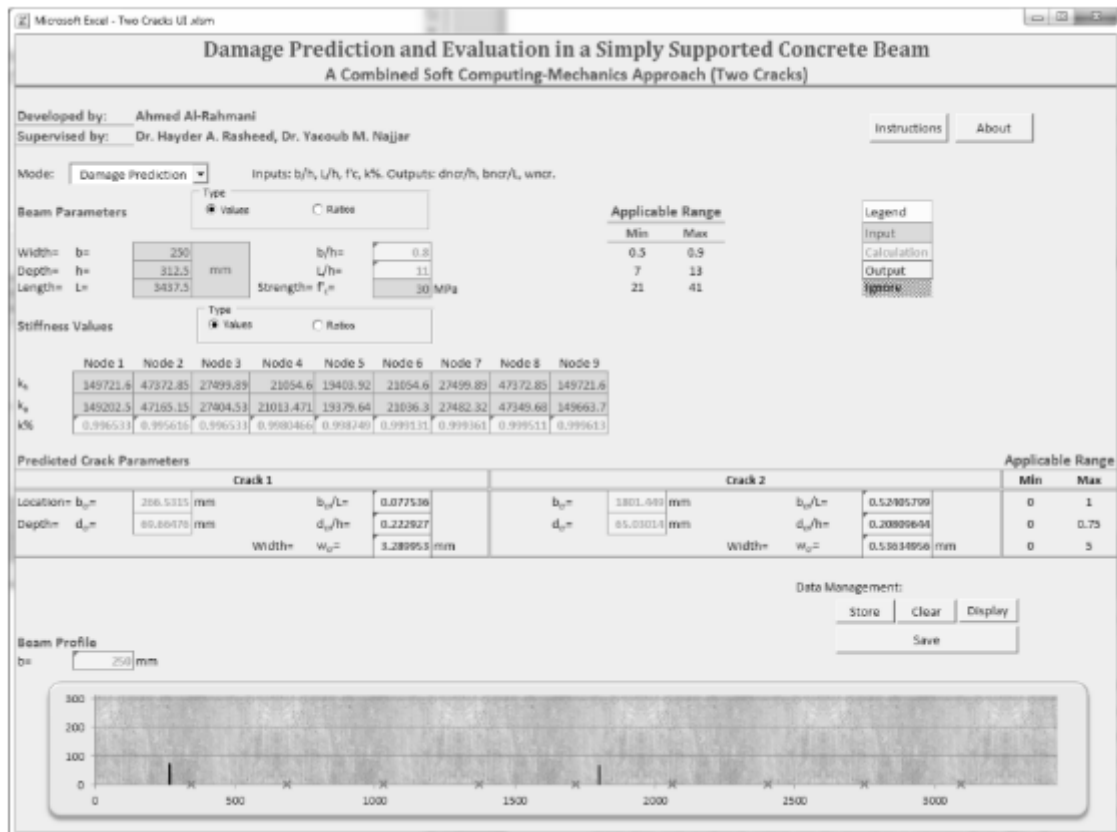
Antarmuka Excel pertama mengintegrasikan ANN fase I dan III. Pengguna dapat memilih untuk menggunakan model ANN_I-1 atau model ANN_I-8, 9, dan 10 untuk memprediksi retakan tunggal pada balok yang ditopang secara sederhana. ANN_I memprediksi semua parameter keluaran dalam satu model, sementara ANN_I-8–10 memprediksi setiap parameter keluaran dalam ANN yang independen. Sebagai alternatif, pengguna dapat memilih model ANN_{III} yang lebih akurat yang dikembangkan berdasarkan elemen hingga tegangan bidang. Deskripsi model juga disediakan dalam antarmuka agar dapat ditinjau oleh pengguna. Selanjutnya, pengguna dapat memilih untuk memasukkan parameter balok dalam format nilai absolut atau ternormalisasi.

Input untuk format eksak adalah kuat tekan ($f'c$), lebar (b), kedalaman (h), dan panjang bentang (L) balok, sedangkan input untuk format ternormalisasi adalah rasio lebar terhadap kedalaman (b/h), rasio panjang bentang terhadap kedalaman (L/h), dan kuat tekan ($f'c$). Demikian pula, pengguna juga dapat memilih untuk memasukkan nilai kekakuan dalam format nilai eksak atau ternormalisasi. Input untuk format eksak adalah nilai kekakuan untuk balok yang dimaksud (kna) dan nilai kekakuan untuk balok yang sama dalam keadaan awal atau sehat (knh), sedangkan input untuk format ternormalisasi adalah rasio kekakuan ($kn\%$) sebagaimana didefinisikan sebelumnya.



Gambar 13.17: Antarmuka pengguna Excel untuk fase I dan III yang beroperasi dengan model ANNi-1.

Selanjutnya, antarmuka segera menyediakan parameter retak yang diprediksi oleh ANN untuk input ini dalam format ternormalisasi dan/atau eksak, bergantung pada format parameter balok input yang diberikan. Selain itu, antarmuka dapat menentukan di separuh bentang mana retakan berada dan memberi tahu pengguna apakah nilai kekakuan harus dibalik. Antarmuka juga menyediakan representasi grafis profil balok dan menunjukkan letak retakan dalam bentang balok serta kedalamannya relatif terhadap kedalaman balok. Plot juga menunjukkan lokasi simpul kekakuan dengan tanda 'x' merah. Gambar 13.17 menunjukkan antarmuka yang dikembangkan untuk fase I dan III.



Gambar 13.18: Antarmuka pengguna Excel yang dikembangkan untuk ANNli dalam mode "Prediksi Kerusakan".

Untuk fase II, antarmuka dimodifikasi untuk memudahkan prediksi dua retakan. Pertama, pengguna memilih mode operasi yang diinginkan. Pengguna dapat memilih mode "Prediksi Kerusakan" untuk memprediksi kedalaman, lebar, dan lokasi retakan dengan memberikan parameter balok dan nilai kekakuan, atau memilih mode "Evaluasi Kerusakan" untuk menentukan indeks kesehatan dengan memberikan parameter balok dan retakan. Selanjutnya, pengguna dapat memilih untuk memasukkan parameter balok dalam format nilai absolut atau ternormalisasi.

Masukan untuk format eksak adalah kuat tekan (f'_c), lebar (b), kedalaman (h), dan panjang bentang (L) balok, sedangkan masukan untuk format ternormalisasi adalah rasio lebar terhadap kedalaman (b/h), rasio panjang bentang terhadap kedalaman (L/h), dan kuat tekan (f'_c). Langkah selanjutnya bergantung pada mode operasi yang dipilih pengguna. Jika antarmuka beroperasi dalam mode "Prediksi Kerusakan", yang menjadi fokus bab ini, pengguna kemudian memilih untuk memasukkan nilai kekakuan dalam format nilai eksak atau ternormalisasi. Masukan untuk format eksak adalah nilai kekakuan untuk balok yang dimaksud (k_{na}) dan nilai kekakuan untuk balok yang sama dalam keadaan awal atau sehat (k_{nh}), sedangkan masukan untuk format ternormalisasi adalah rasio kekakuan ($k_n\%$) sebagaimana didefinisikan sebelumnya.

Antarmuka kemudian segera menyediakan parameter retak yang diprediksi oleh ANN untuk masukan ini dalam format ternormalisasi dan/atau eksak, bergantung pada format parameter balok masukan yang diberikan. Selain itu, antarmuka menyediakan representasi grafis profil balok dan menunjukkan letak kedua retakan dalam bentang balok serta kedalamannya relatif terhadap kedalaman balok. Plot juga menunjukkan lokasi simpul kekakuan dengan tanda 'x' merah. Gambar 13.18 menunjukkan antarmuka yang dikembangkan untuk fase II dalam mode "Prediksi Kerusakan".

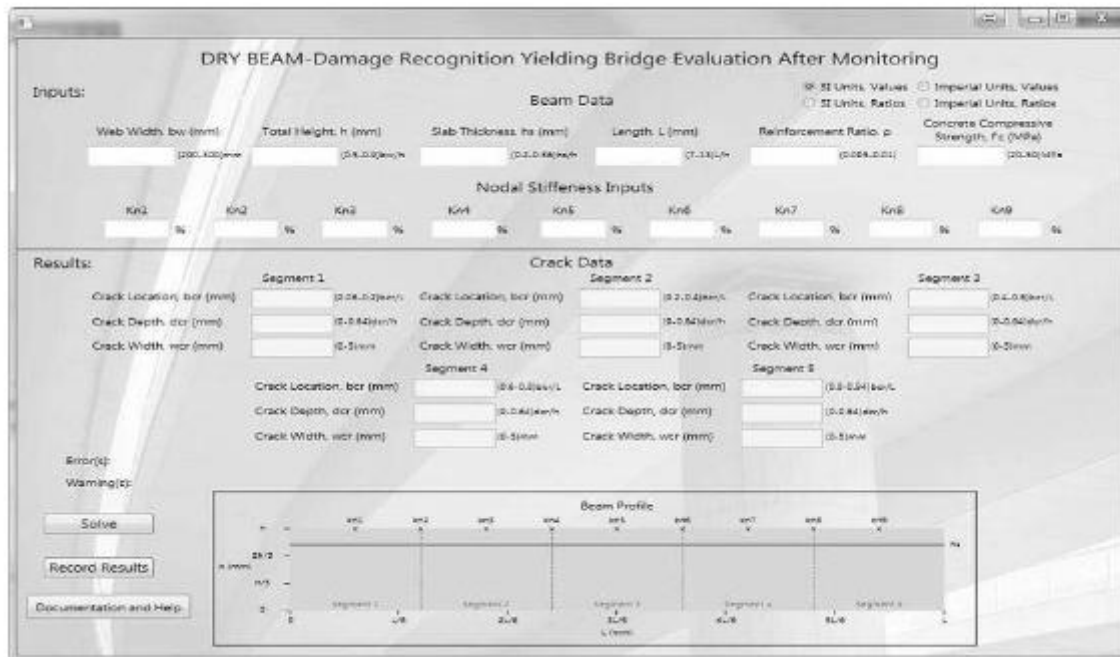
Antarmuka Perangkat Lunak Analisis 3D

Setelah menerapkan proses pelatihan ANN dan prosedur pemilihan model optimal serta mengevaluasi akurasi prediksi model berkinerja terbaik pada set data pengujian tambahan, arsitektur ANN optimal untuk aplikasi prediksi parameter retak ditetapkan. Bias dan bobot koneksi untuk lapisan masukan-lapisan tersembunyi dan lapisan tersembunyi-lapisan keluaran diambil setelah arsitektur jaringan ini dilatih pada semua data dalam basis data utama.

Penerapan bias dan bobot koneksi ini pada fungsi penjumlahan dan aktivasi yang dijelaskan memungkinkan perhitungan parameter retak yang diprediksi oleh ANN untuk setiap balok-T beton bertulang dengan tumpuan sederhana yang memiliki parameter dalam rentang yang digunakan untuk membuat basis data model elemen hingga (FE). Untuk mengotomatiskan perhitungan ini dan memfasilitasi evaluasi kerusakan di lapangan, di lapangan, dengan menggunakan model ANN optimal, sebuah aplikasi komputer berbasis antarmuka pengguna sentuh dikembangkan.

Aplikasi ini dikembangkan dengan Visual Studio 2015 menggunakan .NET Framework versi 4.5 pada desktop yang menjalankan sistem operasi Windows. Gambar 13.19 menampilkan versi akhir antarmuka pengguna grafis yang dapat dimuat pada PC tablet dan digunakan untuk prediksi lapangan. Seperti yang ditunjukkan pada Gambar 13.19, antarmuka pengguna menerima parameter geometri dan material (b_w , h , h_s , L , ρ , dan f'_c) di bagian "Data Balok" dan rasio kekakuan nodal (K_n %) di bagian "Kekakuan Nodal" sebagai masukan. Setelah tombol 'Selesaikan' diaktifkan, parameter masukan dinormalisasi untuk berfungsi sebagai simpul masukan untuk perhitungan ANN.

Bias dan bobot koneksi dari parameter retakan optimal model ANN diterapkan untuk meneruskan parameter masukan ke simpul tersembunyi dan akhirnya ke simpul keluaran. Parameter keluaran kemudian didenormalisasi, dan parameter retak yang diprediksi ditampilkan di bagian 'Hasil' di bagian bawah antarmuka pengguna. Selain itu, setelah menekan tombol 'Selesaikan', "Profil Balok" akan diperbarui untuk menampilkan lokasi flensa balok-T serta lokasi dan kedalaman setiap retakan. Label tinggi dan panjang juga diubah untuk mencerminkan tinggi dan panjang balok yang dimasukkan pengguna.



Gambar 13.19 Antarmuka pengguna grafis prediksi kerusakan retakan (DRY BEAM).

13.6 KESIMPULAN

Serangkaian studi komprehensif telah dilakukan pada balok persegi panjang 2D dengan tumpuan sederhana dan balok T 3D dengan tumpuan sederhana menggunakan pendekatan sinergi AI-FE yang dijelaskan secara rinci dalam bab ini. Hasil yang dihasilkan pada semua tingkat pemodelan dan prediksi AI mendukung kesimpulan berikut:

1. Metodologi sinergi AI-FE yang diusulkan menawarkan kerangka kerja yang kuat untuk mendeteksi kerusakan pada jembatan beton bertulang dan balok bangunan.
2. Berkat penggunaan model ANN yang telah dilatih, diuji, dan divalidasi, dimungkinkan untuk menghasilkan alat prediksi yang sangat cepat yang dapat diterapkan untuk inspeksi lapangan asalkan basis data FE parameter kerusakan telah ditentukan sebelumnya atau dihasilkan sebelumnya.
3. Ukuran akurasi model ANN yang dibangun semuanya berada dalam rentang prediksi yang wajar terlepas dari kompleksitas kerangka kerja analisis yang digunakan dan jumlah parameter kerusakan yang terlibat.
4. Meskipun nilai ukuran akurasi rendah karena kemungkinan solusi yang tidak unik, kerusakan yang terdeteksi secara praktis sangat wajar dibandingkan dengan kerusakan aktual karena nilai parameter retak yang kecil dibandingkan dengan ukuran balok. Hal ini terutama berlaku untuk lebar retakan.
5. Hasil penelitian menunjukkan bahwa model ANN dapat memprediksi parameter retakan terpenting (lokasi retakan) dengan sangat akurat, sementara model ini dapat memprediksi kedalaman retakan dengan akurasi yang lebih rendah namun cukup baik.
6. Perangkat lunak yang dikembangkan menggunakan perangkat sentuh terbukti sangat ampuh dalam mengimbangi atau mengurangi ketergantungan pada teknik deteksi kerusakan subjektif dengan membuka jalan menuju penerapan alat yang lebih objektif.

BAB 14

PEMBELAJARAN MENDALAM DALAM SISTEM SIBER-FISIK TRANSPORTASI

14.1 PENDAHULUAN

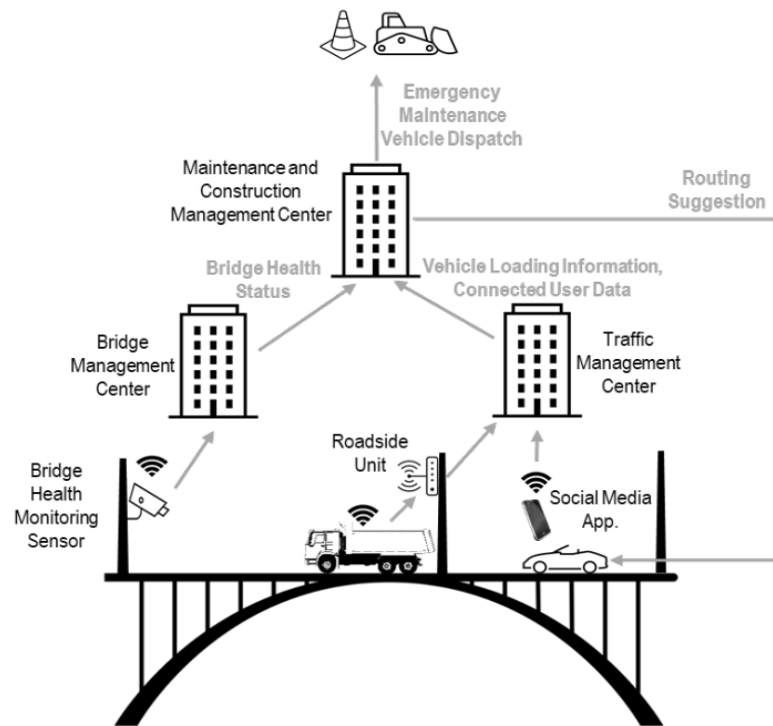
Sistem Siber-Fisik Transportasi (TCPS) didefinisikan sebagai sistem yang memastikan "efisiensi dan keandalan yang lebih tinggi dengan memungkinkan peningkatan interaksi berbasis umpan balik antara sistem siber dan sistem fisik dalam transportasi" (Deka dkk., 2018; Zeng dkk., 2020). Namun, sebagaimana dibahas dalam studi terbaru, domain sosial, yang terdiri dari pemangku kepentingan manusia yang dilayani oleh TCPS, harus menjadi salah satu titik fokus dari keseluruhan desain sistem.

Dengan demikian, TCPS mengintegrasikan interaksi antara infrastruktur transportasi yang terhubung, pengguna, dan layanan komputasi dan komunikasi, baik di infrastruktur edge maupun cloud melalui loop umpan balik untuk meningkatkan penerimaan sosial terhadap keseluruhan sistem. Gambar 14.1 menunjukkan contoh skenario TCPS pemantauan kondisi jembatan di mana data dikumpulkan dari sensor pemantauan jembatan, truk yang terhubung, dan pengguna ponsel pintar. Truk yang terhubung akan berbagi status real-time truk, dan pengguna smartphone lainnya akan terhubung melalui aplikasi atau aplikasi smartphone (termasuk aplikasi media sosial atau aplikasi navigasi seperti Waze, di mana pengguna dapat memberikan masukan).

Sistem keseluruhan ini didukung oleh arsitektur yang berpusat pada tepi, di mana unit pinggir jalan adalah perangkat tepi tetap yang berkomunikasi dengan perangkat tepi tetap lainnya (sensor pemantauan jembatan) dan perangkat tepi seluler (truk yang terhubung). Pusat pemantauan jembatan (BMC) adalah tepi sistem yang mengumpulkan data dari sensor pemantauan kesehatan jembatan, seperti kamera, sedangkan data dari truk yang terhubung dan aplikasi smartphone diteruskan ke pusat manajemen lalu lintas (TMC). Baik BMC maupun TMC menganalisis data yang dikumpulkan dan selanjutnya memberi tahu pusat manajemen darurat jika ada perbaikan jembatan yang segera diperlukan.

Pusat manajemen darurat dapat menyarankan rute alternatif atau peringatan rute, yang akan menguntungkan lalu lintas yang mendekati dan pengguna jalan lainnya. TCPS tersebut, bersama dengan banyak TCPS lainnya, membantu masyarakat dengan:

- Meningkatkan keselamatan dan mobilitas bagi pengguna jalan yang rentan seperti pejalan kaki
- Mengadaptasi operasional sistem transportasi berdasarkan masukan waktu nyata (real-time) dan non-waktu nyata (non-real-time) dari pengguna dan pemangku kepentingan lainnya
- Memungkinkan interaksi manusia-mesin yang cerdas
- Memaksimalkan penerimaan pengguna.



Gambar 14.1 TCPS untuk pemantauan kondisi Jembatan.

14.2 KECERDASAN BUATAN, PEMBELAJARAN MESIN, DAN PEMBELAJARAN MENDALAM

Konsep pembelajaran mesin (ML) dan pembelajaran mendalam (DL) berevolusi dari Kecerdasan Buatan (AI). Jika sebuah mesin dapat menghasilkan perilaku cerdas, ia dapat disebut sebagai mesin yang mendukung AI. Sebagai program komputer, ML digunakan untuk mempelajari hubungan antara masukan dan keluaran melalui observasi data. Dalam ML, program tidak dirancang secara eksplisit oleh pemrogram. Program dapat belajar dari: (1) data masukan, (2) matriks perhitungan kesalahan yang menghitung selisih antara data prediksi dan data nyata, dan (3) loop umpan balik berdasarkan metrik perhitungan kesalahan. Jaringan Syaraf Tiruan (Neural Network) adalah salah satu jenis ML.

Pembelajaran mendalam (Deep Learning) adalah jenis ML yang spesifik, khususnya jaringan syaraf tiruan, di mana lapisan tambahan ditambahkan agar program dapat mempelajari lebih detail melalui pelatihan. Setiap lapisan dalam DL berisi banyak neuron. Domain pembelajaran mesin asli memiliki jaringan syaraf tiruan dangkal (shallow neural network), regresi logistik, dan mesin vektor pendukung (support vector machine). Bahasa Indonesia: Untuk mengimbangi pertumbuhan data yang tersedia dan peningkatan terkini dalam kapabilitas perangkat keras (seperti pengenalan unit pemrosesan grafis (GPU), DL telah menjadi metode yang ampuh untuk mengatasi masalah dunia nyata yang kompleks karena model ini dapat secara otomatis mengekstraksi fitur dari data yang kompleks.

Model ML tradisional memerlukan ekstraktor fitur eksternal untuk mengekstraksi fitur yang relevan dari data. Contoh kasus penggunaan adalah klasifikasi gambar, di mana akurasi telah meningkat menjadi sekitar 96–97%, yang bahkan lebih baik daripada akurasi yang dicapai oleh manusia (Pouyanfar et al., 2018). DL dapat digunakan dengan data sensor dunia nyata skala besar, seperti gambar, video, ucapan, audio, dan teks. Yang terpenting, DL

adalah teknologi yang paling dekat yang diketahui yang paling mirip dengan fungsi otak manusia.

14.3 SEJARAH SINGKAT PEMBELAJARAN MENDALAM

Sejarah jaringan saraf dalam berawal dari perangkat kognisi elektronik, perceptron. Setelah itu, penemuan teknik backpropagation membuka jalan bagi jaringan saraf modern. Pada tahun 1980-an, konsep dasar di balik jaringan saraf konvolusional dan rekuren diperkenalkan. LeNet adalah jaringan saraf pertama yang dikembangkan pada tahun 1990-an, tetapi tidak praktis untuk kumpulan data besar karena keterbatasan perangkat keras.

Mesin Boltzmann terbatas (RBM) juga diperkenalkan sekitar waktu itu, yang merupakan model dua lapis tanpa pengawasan. Sebuah terobosan datang pada tahun 2006 ketika jaringan keyakinan dalam (DBN) diusulkan. DBN memungkinkan kemampuan untuk menambahkan lebih banyak lapisan dan melatih satu lapisan pada satu waktu, yang memunculkan kelas model 'dalam'. Hasilnya, lahirlah jaringan saraf dalam. Setelah itu, jaringan konvolusi dan jaringan rekursif diterapkan untuk menciptakan jaringan saraf dalam dengan berbagai jenis. Metode pelatihan awal dimodifikasi untuk melatih semua lapisan sekaligus, alih-alih melatih lapis demi lapis.

Dua revolusi terbesar belakangan ini adalah big data dan perangkat keras komputasi. Ketersediaan data heterogen dalam jumlah besar dan pengenalan perangkat keras komputasi skala besar telah memungkinkan model pembelajaran jarak jauh (DL) untuk mengungguli model pembelajaran mesin (ML) sebelumnya. Contoh kemajuan yang dicapai DL adalah AlphaGo milik Google, yang memenangkan 60 pertandingan "Go" berturut-turut melawan pemain manusia, termasuk juara "Go" selama tahun 2016 dan 2017.

14.4 MODEL PEMBELAJARAN MENDALAM UNTUK APLIKASI TCPS

Model Pembelajaran Mendalam Awal

Perbedaan utama antara jaringan saraf tiruan awal/tradisional dan lanjutan adalah bahwa jaringan tradisional dilatih dengan metode greedy berlapis-lapis. Terdapat banyak variasi jaringan tersebut, yang dijelaskan di bawah ini.

Mesin Boltzmann Terbatas (RBM)

Dalam RBM, semua neuron adalah variabel biner, dan seluruh distribusi probabilitas mengikuti distribusi Boltzmann. Jaringan RBM terdiri dari lapisan masukan dan lapisan tersembunyi. Aktivasi lapisan tersembunyi bersifat independen dari lapisan masukan. Dengan menggunakan lapisan tersembunyi yang memadai, semua distribusi diskrit dapat disesuaikan dengan mesin Boltzmann, yang merupakan jaringan unit-unit mirip neuron, yang terhubung secara simetris.

Jaringan Keyakinan Mendalam (DBN)

DBN berisi beberapa jaringan tanpa pengawasan, yang dapat mencakup autoencoder atau RBM. Terdapat banyak lapisan tersembunyi dalam DBN. Lapisan tersembunyi tersebut dapat dilatih dengan metode greedy per lapisan. Aspek lain dari DBN adalah tidak adanya koneksi antar neuron di setiap lapisan, tidak seperti jaringan saraf tiruan modern. Lapisan-

lapisan tersebut hanya berisi satu koneksi, yang meneruskan keluaran dari lapisan terakhir sebagai masukan ke lapisan berikutnya. Lapisan atas dan bawah terhubung untuk memberikan umpan balik. Targetnya adalah rekonstruksi masukan, sehingga DBN juga merupakan model tanpa pengawasan. Setelah fase pembelajaran, DBN juga dapat digunakan untuk klasifikasi.

Mesin Boltzmann Dalam (DBM)

DBM mirip dengan DBN karena juga terdiri dari beberapa RBM. Perbedaannya terletak pada koneksi searah dan tidak adanya umpan balik dari lapisan atas ke bawah. DBM berisi banyak lapisan tersembunyi. Ekspektasi yang diestimasi mencakup ekspektasi yang bergantung pada data menggunakan aproksimasi variasional dan ekspektasi yang tidak bergantung pada data menggunakan rantai Markov. Kedua ekspektasi ini dimasukkan ke dalam gradien fungsi log-likelihood. Pembelajaran diimplementasikan menggunakan metode tanpa pengawasan, di mana model dilatih dalam satu lintasan maju lapis demi lapis. DBM lebih kuat dan robust daripada DBN karena dapat mengekstrak fitur dari data yang lebih samar dan data yang kompleks, seperti sinyal suara atau ucapan.

Multilayer Perceptron (MLP)

MLP adalah bentuk paling sederhana dari jaringan saraf tiruan dalam. MLP memiliki beberapa lapisan tersembunyi di antara lapisan masukan dan keluaran. Jika semua neuron saling terhubung, maka jaringan ini dikenal sebagai MLP yang terhubung penuh. Koneksi antar setiap lapisan terdiri dari serangkaian parameter bobot. Mari kita asumsikan m sebagai lapisan masukan, n sebagai lapisan keluaran, dan h_1 dan h_2 sebagai lapisan tersembunyi.

Bobot antar lapisan masing-masing adalah W_1 , W_2 , dan W_3 . Setiap lapisan berisi fungsi aktivasi σ . Beberapa fungsi aktivasi yang populer adalah tanh, sigmoid, dan unit linier terrektifikasi atau ReLU. Fungsi ini menambahkan non-linearitas ke dalam model, yang diperlukan untuk memodelkan non-linearitas permasalahan dunia nyata yang kompleks. MLP menggabungkan perkalian matriks, penjumlahan, dan aktivasi non-linier, seperti yang ditunjukkan menggunakan Persamaan (14.1–14.3) berikut.

$$h_1 = \sigma(W_1 m + b_1) \quad (14.1)$$

$$h_2 = \sigma(W_2 h_1 + b_2) \quad (14.2)$$

$$\hat{n} = \sigma(W_3 h_2 + b_3) \quad (14.3)$$

Bobot diperbarui selama pelatihan berdasarkan data lapisan masukan. Teknik backpropagation dapat digunakan untuk menghitung gradien fungsi kerugian untuk memperbarui bobot. Hasilnya, bobot dimodifikasi untuk meminimalkan kerugian pelatihan.

Autoencoder

Autoencoder atau autoencoder adalah kombinasi jaringan encoder dan decoder. Jaringan encoder mengekstrak fitur laten menggunakan data pelatihan, dan jaringan decoder menggunakan fitur-fitur ini untuk merekonstruksi masukan. Kerugian rekonstruksi diminimalkan dalam proses pelatihan untuk mendapatkan representasi terbaik fitur yang

dikodekan dari masukan. Karena proses pembelajarannya otomatis, proses ini disebut encoder otomatis.

Penggunaan pertama autoencoder adalah sebagai denoiser. Baru-baru ini, autoencoder sangat populer untuk reduksi dimensionalitas dan ekstraksi fitur. Autoencoder juga berguna ketika data berlabel tidak tersedia karena proses pelatihannya otomatis dan tidak memerlukan label keluaran. Jenis autoencoder lainnya adalah autoencoder variasional. Dalam model ini, metode inferensi variasional digunakan untuk meminimalkan kerugian rekonstruksi masukan.

Jaringan Syaraf Tiruan Konvolusional (CNN)

CNN dirancang khusus untuk sepenuhnya memanfaatkan properti struktur data 2D (yaitu, gambar). Karakteristik utama CNN adalah operasi konvolusi. Filter kecil digunakan untuk menerapkan operasi konvolusi pada bagian kecil gambar, alih-alih keseluruhan gambar. Filter kecil ini dikenal sebagai kernel. Hal ini memungkinkan ekstraksi korelasi lokal spasial dalam data. Proses ini menghasilkan pengurangan bobot, sehingga jaringan menjadi lebih cepat. Model CNN yang umum berisi beberapa lapisan konvolusi dan penggabungan (yaitu, penggabungan maksimum atau penggabungan rata-rata).

Lapisan penyatuan digunakan untuk mengurangi dimensionalitas masukan menggunakan pengambilan sampel turun. Lapisan yang diratakan dan beberapa lapisan yang terhubung penuh mengikuti urutan beberapa lapisan konvolusi dan penyatuan. Lapisan-lapisan ini diperlukan untuk mendapatkan jumlah label atau prediksi yang diinginkan pada lapisan keluaran. Mari kita asumsikan I adalah citra masukan kanal tunggal dengan ukuran (P, Q) , K adalah kernel dengan ukuran (X, Y) , dan h adalah citra keluaran. Kemudian, operasi konvolusi untuk setiap piksel dalam h dapat dinyatakan menggunakan Persamaan (14.4) berikut.

$$h_{i,j} = \sum_{x=1}^X \sum_{y=1}^Y I(i+x-1, j+y-1)K(x, y) \quad (14.4)$$

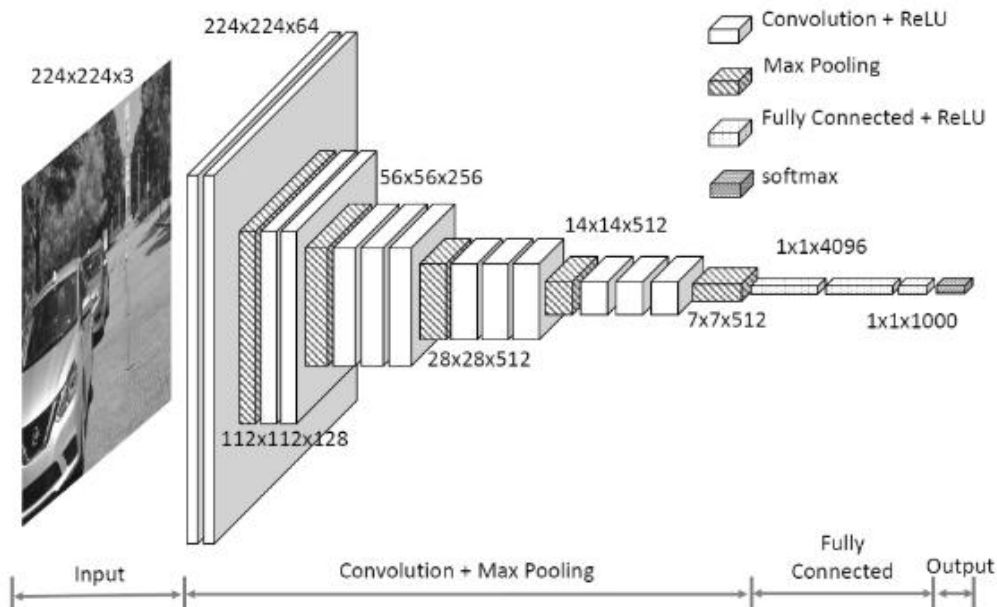
di mana $h_{i,j}$ diperoleh setelah fungsi aktivasi nonlinier digunakan di atas konvolusi. Dimensi $h_{i,j}$ akan menjadi $(P-M+1, Q-N+1)$. Jika n kernel tersebut digunakan untuk menghasilkan sampel, data berdimensi $(P-M+1, Q-N+1, n)$ akan dihasilkan. Jika ukuran filter penggabungan dari lapisan penggabungan adalah R , maka keluaran lapisan penggabungan akan memiliki dimensi $[(P-M+1)/R, (Q-N+1)/R, n]$.

Pada dasarnya, lapisan penggabungan membagi masukan menjadi blok-blok berukuran (R, R) dan kemudian melakukan operasi agregasi, seperti rata-rata atau maks. CNN memiliki beberapa lapisan terakhir sebagai lapisan yang terhubung penuh. Jika modelnya adalah model klasifikasi, maka lapisan terakhir berisi fungsi aktivasi yang menghasilkan skor probabilitas setiap kelas. Contoh fungsi aktivasi tersebut adalah sigmoid, SoftMax, dll. Citra dan kernel akan memiliki dimensi tambahan untuk citra RGB (*merah, hijau, biru*) karena citra masukan akan memiliki tiga kanal untuk tiga warna.

Arsitektur CNN pertama kali diusulkan oleh LeCun dkk. (1989) untuk sistem pengenalan kucing berbasis penglihatan. Dalam studi mereka, mereka hanya menggunakan satu kernel untuk operasi konvolusi pada citra masukan dan mengekstraksi fitur lokal di dalam citra. Model CNN menjadi sangat populer akhir-akhir ini seiring dengan pertumbuhan data berlabel. Kumpulan data terpopuler yang terkait dengan klasifikasi citra dan deteksi objek di dalam citra adalah *ImageNet*, *Common Objects In Context (COCO)*, dan *Pascal Visual Object Classes (VOC)*.

Untuk klasifikasi, contoh arsitektur terpopuler adalah AlexNet, VGGNet, Inception, dan Resnet. Untuk deteksi objek dan kotak pembatas (persegi panjang imajiner yang digunakan untuk deteksi objek dalam gambar) di dalam gambar, terdapat beberapa jenis model lain, seperti *Region-CNN (R-CNN)*, *Fast R-CNN*, *Faster R-CNN*, dan *You Only Look Once-Version 3 (YOLOv3)*. Untuk tugas-tugas lain (seperti segmentasi semantik, pengenalan tindakan, dan pengenalan teks), model CNN juga dapat digunakan.

Model VGG-16 ditunjukkan pada Gambar 14.2. Inputnya berupa gambar berukuran $224 \times 224 \times 3$. Arsitekturnya dimulai dengan dua lapisan konvolusional dan max-pooling dengan ukuran filter 2. Setelah tiga lapisan ini, dimensi barunya adalah $112 \times 112 \times 128$. Proses yang sama diulang untuk mendapatkan dimensi baru $56 \times 56 \times 256$. Setelah itu, terdapat tiga lapisan konvolusi dan maxpooling dengan ukuran filter 2. Dimensi terakhir sebelum lapisan perataan adalah $7 \times 7 \times 512$. Setelah perataan, lapisan perataan berisi 4.096 neuron. Kemudian, lapisan perataan terhubung ke lapisan terhubung penuh dengan 1.000 neuron. Terakhir, lapisan SoftMax digunakan untuk mengonversi keluaran menjadi nilai probabilitas.



Gambar 14.2: Arsitektur model VGG-16.

Jaringan Syaraf Tiruan Berulang (RNN)

Sama seperti CNN, RNN dirancang khusus untuk data sekuensial, seperti data deret waktu. RNN khususnya berguna untuk peramalan deret waktu, pemrosesan bahasa alami (NLP), pemrosesan ucapan, dan sebagainya. RNN menyimpan representasi masukan jangka

pendek dan jangka panjang serta menggunakan koneksi umpan balik untuk meneruskan informasi guna memprediksi langkah selanjutnya.

Pemrosesan data masukan secara sekuensial memungkinkan masukan dengan panjang variabel, yang merupakan keunggulan lain dari model RNN. Persamaan dasar (14.5) untuk menjelaskan model RNN diberikan di bawah ini.

$$h_t = \sigma(Wm_t + Uh_{t-1}) \quad (14.5)$$

di mana W dan U masing-masing adalah matriks bobot untuk koneksi ke langkah waktu saat ini dan sebelumnya. RNN tradisional mengalami dua masalah utama, yaitu gradien menghilang dan gradien meledak. Gradien menghilang terjadi ketika perkalian banyak gradien kecil dapat membuat gradien resultan mendekati nol. Akibatnya, efek variasi jangka panjang mungkin hilang untuk langkah waktu saat ini. Masalah sebaliknya adalah masalah gradien meledak, di mana perkalian banyak gradien besar dapat menghasilkan nilai gradien yang sangat tinggi. Hal ini membuat jaringan tidak stabil, dan model tidak dapat mempelajari apa pun dari data.

Hasil dari kedua masalah ini adalah jaringan secara bertahap melupakan masukan awal ketika data baru masuk. Untuk mengatasi hal ini, jaringan saraf Memori Jangka Panjang dan Jangka Pendek (LSTM) telah dikembangkan. Operasi tambahan yang digunakan dalam neuron LSTM untuk mengatasi masalah gradien menghilang ditunjukkan pada Gambar 14.3. Keadaan sel (c) bertindak sebagai memori model LSTM. Keadaan sel memecahkan masalah gradien yang menghilang dan meledak dengan menggunakan operasi aditif dan perkalian titik demi titik.

Operasi-operasi ini digunakan untuk memperbarui informasi memori. Neuron LSTM berisi gerbang masukan, gerbang lupa, dan keluaran dengan fungsi aktivasi '*tanh*'. Operasi matematika ditunjukkan menggunakan Persamaan berikut (14.6– 14.10) (m_t , c_{t-1} , dan n_{t-1} adalah masukan ke model. n_t dan c_t adalah keluaran model. σ mengacu pada fungsi aktivasi sigmoid).

Dari gerbang lupa, masukan, dan keluaran, f_t , i_t , dan o_t masing-masing dihasilkan. Bobot yang terkait dengan setiap gerbang direpresentasikan menggunakan W , U , dan b . Perkalian elemen demi elemen direpresentasikan oleh titik (.) dalam persamaan.

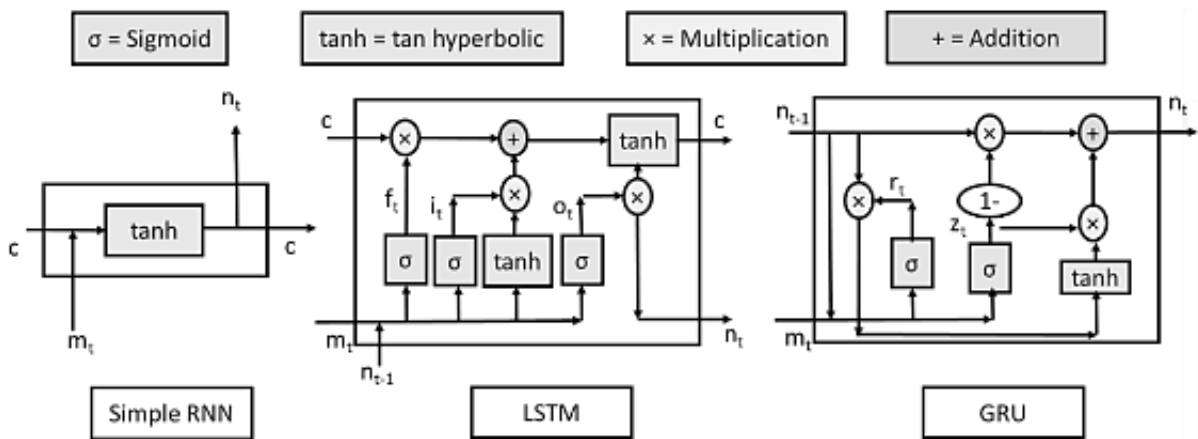
$$f_t = \sigma(W_f m_t + U_f n_{t-1} + b_f) \quad (14.6)$$

$$i_t = \sigma(W_i m_t + U_i n_{t-1} + b_i) \quad (14.7)$$

$$o_t = \sigma(W_o m_t + U_o n_{t-1} + b_o) \quad (14.8)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(W_c m_t + U_c n_{t-1} + b_c) \quad (14.9)$$

$$n_t = o_t \cdot \tanh(c_t) \quad (14.10)$$



Gambar 14.3: Model RNN, LSTM, dan GRU.

Versi modifikasi neuron LSTM diciptakan untuk mengurangi kompleksitasnya, yang dikenal sebagai *Gated Recurrent Unit* (GRU). Sebuah "gerbang pembaruan" baru diciptakan di GRU, yang menggabungkan gerbang masukan dan gerbang lupa. Status sel dan status tersembunyi digabungkan untuk operasi yang lebih cepat. Persamaan 14.11–14.13 menjelaskan operasi matematika di balik GRU, dengan status antara z_t dan r_t .

$$z_t = \sigma(W_z m_t + U_z n_{t-1} + b_z) \tag{14.11}$$

$$r_t = \sigma(W_r m_t + U_r n_{t-1} + b_r) \tag{14.12}$$

$$n_t = z_t \cdot n_{t-1} + (1 - z_t) \cdot \tanh(W_n m_t + U_n (n_{t-1} \cdot r_t) + b_n) \tag{14.13}$$

RNN sederhana, LSTM, dan GRU semuanya memiliki varian dua arah, dan pelatihannya serupa dengan yang satu arah.

Pembelajaran Penguatan Mendalam

Pembelajaran penguatan atau RL adalah cabang khusus lain dari ML di mana agen dilatih untuk mengambil tindakan yang tepat berdasarkan observasi dari lingkungan. Agen memulai dengan tindakan acak dan kemudian mengamati efeknya. Imbalan yang diamati dan status saat ini dimasukkan ke model untuk mengidentifikasi langkah selanjutnya. Maksimalisasi imbalan jangka panjang dianggap sebagai tujuan. Algoritma RL biasanya didasarkan pada Proses Keputusan Markov (MDP).

MDP adalah sistem yang berisi sekumpulan agen, status, tindakan, dan beberapa keacakan, di mana setiap tindakan membawa agen dari satu status ke status lainnya dengan beberapa ketidakpastian. Algoritma RL menggunakan fungsi nilai status dan fungsi kualitas (fungsi-Q, juga disebut sebagai fungsi nilai-tindakan). Dalam pendekatan fungsi-Q, fungsi tersebut memberikan hasil yang diharapkan untuk status dan tindakan tertentu. Pendekatan Q-learning dapat digunakan untuk mengaproksimasi nilai Q, dan jaringan saraf dalam dapat digunakan untuk memprediksi nilai Q optimal. Deep Q Network (DQN) adalah metode

DL yang populer untuk RL. Dalam metode ini, model CNN dan lapisan yang terhubung penuh digunakan untuk memprediksi nilai Q, tetapi telah menunjukkan beberapa ketidakstabilan untuk solusi RL.

Stabilitas jaringan RL dapat ditingkatkan dengan menggunakan relai pengalaman dan jaringan target. Perbaikan pada model DQN juga telah diusulkan, termasuk model DQN ganda dan DQN duel. Dalam DQN ganda, dua jaringan terpisah digunakan untuk mengaproksimasi nilai Q, satu adalah jaringan daring, dan yang lainnya adalah jaringan target. Jaringan daring diperbarui secara real-time, tetapi jaringan target diperbarui secara berkala, yang memecahkan masalah estimasi nilai Q yang terlalu tinggi dan ketidakstabilan dalam nilai target. DQN duel terdiri dari arsitektur model non-sekuensial, di mana jaringan DL inti bercabang menjadi dua jalur. Salah satu cabang menghasilkan fungsi nilai yang sesuai dengan suatu status, dan fungsi lainnya menghasilkan keunggulan suatu tindakan tertentu dibandingkan tanpa tindakan. Pada dasarnya, kombinasi kedua nilai ini dapat menghasilkan nilai Q.

Model Lainnya

Model Atensi

Model atensi berfokus pada konteks, alih-alih prediksi aktual. Ini adalah salah satu jenis DNN yang mengumpulkan konteks dan kemudian membuat prediksi. Komputasi pada waktu tertentu hanya difokuskan pada fitur berlapis, alih-alih keseluruhan model. Model ini telah diterapkan pada permasalahan NLP.

Jaringan Adversarial Generatif

Jaringan adversarial generatif (GAN) adalah jenis metode DL yang sepenuhnya berbeda dibandingkan dengan semua model lainnya. Model ini mengekstrak distribusi statistik dari data latih dan menciptakan data sintesis baru. Sifat data sintesis ini adalah sangat mirip dengan data asli, sehingga dapat digunakan untuk augmentasi data, atau denoising. Model ini mencoba memaksimalkan kemungkinan data latih. Model ini memiliki dua bagian: generatif dan diskriminatif. Model generatif menciptakan data sintesis dengan melewati derau atau gangguan acak melalui jaringan multilapis.

Derau atau gangguan ini biasanya sangat kecil karena tujuannya adalah menciptakan data seperti data dunia nyata. Model diskriminatif mengidentifikasi apakah sampel tersebut asli atau palsu. Model GAN dasar menggunakan lapisan yang terhubung penuh (*fully-connected layer*) dalam model generatif dan diskriminatif. Dalam GAN konvolusional dalam (DCGAN), normalisasi batch digunakan di semua lapisan, dan tidak ada lapisan penggabungan (*pooling layer*). Variasi lainnya adalah GAN kondisional, di mana pembangkitan dan diskriminasi sampel bersifat kondisional terhadap kelas-kelas tertentu.

14.5 PENGEMBANGAN MODEL PEMBELAJARAN MENDALAM UNTUK APLIKASI TCPS

Fungsi Aktivasi

Fungsi aktivasi merupakan faktor penting dalam pengembangan model pembelajaran mendalam (DL). Sigmoid, tangen hiperbolik, dan ReLU adalah beberapa fungsi aktivasi yang

populer. Misalnya, fungsi sigmoid mengubah masukan apa pun menjadi nilai antara 0 dan 1, yang biasanya sangat membantu untuk tugas klasifikasi biner.

Overfitting DL dan Solusinya

Overfitting DL merupakan masalah umum selama pelatihan. Terkadang model dilatih sedemikian rupa sehingga hanya disesuaikan dengan data pelatihan, alih-alih data yang tidak diketahui, yang menghasilkan akurasi pengujian yang sangat rendah, menggunakan data yang tidak diketahui. Solusi untuk masalah ini adalah regularisasi. Regularisasi mengacu pada sedikit modifikasi algoritma pembelajaran untuk mengurangi overfitting dan meningkatkan kinerja model. Pola umum regularisasi adalah menambahkan beberapa keacakan pada proses pelatihan dan kemudian merata-ratakan keacakan tersebut dalam proses pengujian.

Pembelajaran Transfer

Akses ke perangkat keras komputasi yang canggih tidak selalu memungkinkan, sehingga para peneliti telah menemukan cara untuk menggunakan model yang ada dan bobot yang telah dilatih sebelumnya serta menerapkannya ke domain yang spesifik bagi para peneliti. Teknik ini disebut pembelajaran transfer. Jaringan saraf tiruan dalam dilatih sebelumnya pada kumpulan data yang besar, dan model beserta bobotnya dapat disimpan. Setelah itu, untuk aplikasi yang berbeda, model ini dan bobot pra-latihnya dapat digunakan sebagai titik awal. Kemudian, siapa pun dapat melatih ulang untuk jenis data baru tanpa beban komputasi yang signifikan. Pembelajaran transfer populer karena memungkinkan penggunaan teknik komputasi yang ada untuk mengembangkan model DL secara efisien. Ini juga berguna ketika terdapat kekurangan data pelatihan.

Optimasi Hiperparameter

Teknik optimasi yang paling populer untuk mengurangi fungsi kerugian adalah penurunan gradien stokastik (SGD) yang dapat menunjukkan perilaku berosilasi dan tidak stabil dengan variasi laju pembelajaran. Momentum diperkenalkan untuk meningkatkan kinerja SGD. Peluruhan bobot dan peluruhan pembelajaran adalah dua teknik untuk mengekstraksi laju pembelajaran untuk model SGD. Laju pembelajaran adaptif diperkenalkan menggunakan model Adagrad. Setelah itu, penyempurnaan dilakukan pada model Adadelta, Adamax, dan Adam. Adam adalah teknik optimasi paling populer untuk meminimalkan fungsi kerugian dalam model DL.

Pertimbangan Lain

Memproses data dalam jumlah besar dengan karakteristik yang berbeda (seperti dalam Big Data) secara real-time merupakan salah satu tantangan utama dalam implementasi model DL di dunia nyata. Biasanya, diperlukan perangkat keras komputasi canggih untuk memproses data dalam jumlah besar secara real-time dalam batasan latensi komputasi yang sesuai dari berbagai aplikasi TCPS. Karena kinerja komputasi model DL terutama terkait dengan perangkat keras terkait, penyediaan perangkat keras canggih untuk memenuhi persyaratan kinerja real-time akan meningkatkan biaya penerapan TCPS.

Dengan demikian, kombinasi infrastruktur cloud publik dan infrastruktur edge dapat menjadi cara untuk mengatasi masalah penanganan dan distribusi fungsi pemrosesan Big Data di antara infrastruktur cloud dan edge computing. Meskipun sumber daya komputasi awan

dapat digunakan untuk pelatihan model DL dan validasi kinerja model, latensi komunikasi antara awan (tempat model dilatih dan divalidasi) dan tepi (tempat fungsi dijalankan) dapat membatasi ketergantungan penuh pada teknologi awan. Mentransfer sejumlah besar data melalui jaringan komunikasi dari awan ke tepi akan meningkatkan latensi komunikasi, yang mungkin tidak memenuhi persyaratan waktu nyata aplikasi TCPS berbasis DL.

Teknik pembelajaran terfederasi dapat digunakan untuk mendistribusikan sebagian pelatihan model DL di dalam kendaraan, sebagian di tepi jalan, dan sebagian lagi di awan, secara terdesentralisasi. Namun, menangani jaringan terdistribusi yang heterogen dan masif merupakan tantangan karena kompleksitas implementasi model DL skala besar, optimasi model terdistribusi, dan analisis data yang menjaga privasi. Untuk mencapai kinerja terbaik model DL, perlu dilakukan penyetelan parameter model DL, yang mencakup dua tugas: pencarian arsitektur neural dan penyesuaian hiperparameter. Pencarian arsitektur neural dapat berupa proses otomatis atau manual dalam pengembangan arsitektur DL model apa pun untuk meningkatkan kinerja dengan menemukan struktur model yang optimal. Namun, terdapat dua tantangan utama dalam menemukan arsitektur neural.

Pertama, superstruktur dan substruktur suatu model biasanya dirancang secara heuristik menggunakan pengetahuan manusia sebelumnya, yang membatasi ruang pencarian. Kedua, ruang pencarian yang besar juga menyebabkan komputasi yang mahal dalam proses evaluasi kinerja karena semakin banyaknya model yang perlu diuji. Selain itu, mengeksplorasi set hiperparameter optimal secara efisien dengan memilih metode optimasi terbaik, serta ukuran batch dan laju pembelajaran yang sesuai untuk berbagai model DL merupakan tantangan tersendiri.

14.6 KERANGKA KERJA HARDWARE–SOFTWARE UNTUK PEMBELAJARAN MENDALAM

Perangkat Lunak

Kerangka kerja perangkat lunak yang populer untuk model DL adalah Caffe, Torch, Neon, Theano, MXNet, TensorFlow, dan Microsoft Cognitive Toolkit (CNTK). Python dan C++ adalah dua bahasa pemrograman terpopuler untuk model DL. Semua kerangka kerja mendukung GPU melalui CuDNN. Di antara kerangka kerja tersebut, Torch dan TensorFlow sangat populer di kalangan pengguna Python. Tensorflow menyediakan lapisan pengembangan model tingkat tinggi bernama Keras, yang sangat berguna untuk pengembangan dan implementasi model yang cepat.

Perangkat Keras

Komputasi awan telah mencapai kemajuan yang signifikan, dan model pembelajaran virtual (DL) dapat diterapkan di awan. Namun, untuk komputasi tepi (di mana node komputasi ditempatkan dekat dengan sumber data tepi, diperlukan perangkat komputasi yang kuat. Saat ini, Nvidia Jetson Xavier adalah perangkat komputasi tepi yang populer untuk model DL. Ini terdiri dari GPU Volta, yang berisi integrasi dengan Tensor Cores dan *dual DL Accelerators* (DLA). Xavier dapat memberikan kinerja komputasi 32 TeraFLOP. Nvidia Jetson TX2 adalah perangkat populer lainnya dengan GPU Pascal. TX2 dapat memberikan kinerja lebih dari 1 TeraFlop. Ada banyak sistem tertanam lainnya untuk penerapan model DL, seperti *Intel Neural*

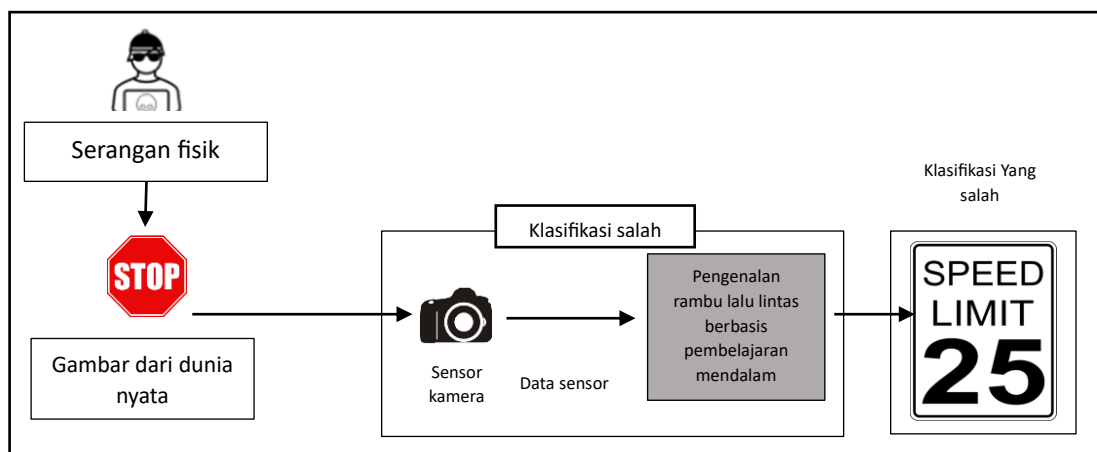
Computing Stick 2 (NCS 2) dan Raspberry Pi 3. Intel NCS 2 menggunakan unit pemrosesan visi (VPU) Myriad X untuk komputasi. Keuntungan perangkat NCS 2 adalah konsumsi daya rendah dan dukungan bawaan untuk kerangka kerja DL seperti Tensorflow dan Caffee.

Kerentanan Pembelajaran Mendalam dalam TCPS

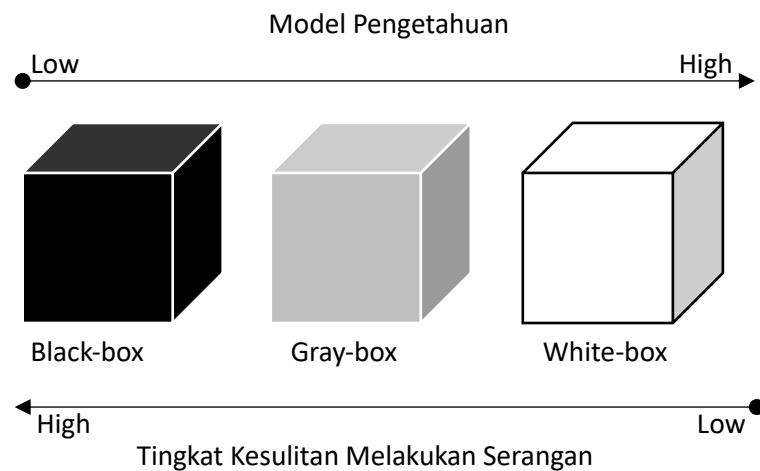
Sebagaimana dibahas di bagian sebelumnya, penggunaan Pembelajaran Mendalam (DL) memungkinkan pemecahan masalah dan peningkatan efisiensi TCPS. Namun, sistem berbasis DL itu sendiri rentan terhadap berbagai serangan siber, yang pada gilirannya dapat mengurangi kegunaan DL dalam TCPS. Beberapa studi menunjukkan bahwa kini dimungkinkan untuk mengelabui sistem berbasis DL. Misalnya, seperti yang ditunjukkan pada Gambar 14.4, seorang penyerang dapat menyerang rambu lalu lintas fisik dan menimbulkan gangguan kecil.

Pengotor yang disuntikkan ke dalam rambu lalu lintas dapat membahayakan modul pengenalan rambu lalu lintas berbasis AI pada kendaraan. Jika modul rambu lalu lintas disusupi dengan cara ini, klasifikasi rambu lalu lintas yang salah akan dihasilkan. Dalam contoh ini, rambu berhenti diidentifikasi sebagai rambu lalu lintas berkecepatan 45 mph. Serangan ini dikenal sebagai serangan adversarial. Penyerang juga dapat membuat serangan siber yang melibatkan gangguan pada data yang ditangkap oleh sensor kamera. Setelah data dikompromikan, keputusan yang salah yang dibuat oleh modul rambu lalu lintas akan mengubah perencanaan kendaraan dan dapat menyebabkan kecelakaan. Bagian ini berfokus pada jenis-jenis serangan siber yang dapat terjadi pada DL, dan area perlindungan DL terhadap serangan siber tersebut dieksplorasi.

Umumnya, model DL biasanya digunakan untuk melakukan deteksi, prediksi, dan klasifikasi. Oleh karena itu, tujuan penyerang adalah menghasilkan keluaran yang salah dengan mengkompromikan model DL sehingga menghasilkan keluaran yang salah, baik yang ditargetkan maupun tidak ditargetkan. Secara lebih luas, serangan siber terhadap model DL dapat dikategorikan menjadi tiga kategori: (1) Model ancaman Whitebox, (2) Model ancaman Blackbox, dan (3) Model ancaman Graybox. Gambar 14.5 menunjukkan ketiga kategori tersebut dan urutan relatifnya berdasarkan pengetahuan penyerang tentang model DL yang digunakan pada sistem target dan tantangan yang dihadapi dalam melakukan serangan.



Gambar 14.4: Contoh serangan siber pada modul pengenalan rambu lalu lintas berbasis DL pada kendaraan otomatis yang terhubung.



Gambar 14.5: Jenis serangan siber dan kesulitan dalam melakukan serangan.

Model Ancaman Whitebox

Dalam serangan Whitebox, penyerang memiliki akses ke pengetahuan model DL yang ingin dikompromikan oleh penyerang. Musuh dapat dengan mudah dibentuk karena penyerang memiliki pengetahuan internal tentang sistem. Pengetahuan ini dapat mencakup struktur model, hiperparameter, dan data pelatihan model DL.

Model Ancaman Blackbox

Dalam pengaturan model blackbox untuk penyerang, penyerang tidak memiliki pengetahuan tentang model DL yang berjalan di dalam sistem. Mari kita pertimbangkan skenario di mana kendaraan otomatis menggunakan model DL untuk mengklasifikasikan rambu lalu lintas. Dalam pengaturan ini, penyerang eksternal mungkin tidak mengetahui arsitektur model dan hiperparameter apa yang berjalan di dalam kendaraan. Namun, penyerang dapat membuat tebakan yang matang bahwa ia akan mengenali jenis rambu lalu lintas tertentu, seperti rambu batas kecepatan dan rambu berhenti, dan melakukan serangan terhadap model blackbox. Namun, jenis serangan ini sulit dilakukan, karena penyerang tidak memiliki pengetahuan tentang sistem.

Model Ancaman Kotak Abu-abu

Serangan kotak abu-abu terjadi ketika penyerang mengetahui lebih sedikit tentang model dibandingkan kotak putih, tetapi lebih banyak daripada kotak hitam. Definisi pasti dari ancaman kotak abu-abu bervariasi. Serangan kotak abu-abu umumnya dibahas sebagai skenario serangan di mana penyerang mengetahui arsitektur model DL target; tetapi tidak mengetahui bobot jaringan DL. Penyerang menggunakan model DL pengganti dengan arsitektur jaringan yang sama untuk melakukan serangan.

14.7 APLIKASI PEMBELAJARAN MENDALAM DALAM TCPS

Prediksi Karakteristik Lalu Lintas

Perkembangan TCPS memungkinkan pengguna jalan untuk menginformasikan kondisi lalu lintas saat ini dan di masa mendatang dengan memanfaatkan informasi lokasi dan gerakan kendaraan secara real-time (misalnya, kecepatan dan akselerasi). Kondisi lalu lintas saat ini dan

di masa mendatang bergantung pada prediksi parameter arus lalu lintas yang akurat. Parameter arus yang diprediksi ini juga dapat digunakan untuk pengalihan rute secara real-time, perencanaan rute, dan penjadwalan guna meningkatkan kondisi operasional dan keselamatan lalu lintas, serta untuk optimalisasi energi guna mengurangi konsumsi bahan bakar kendaraan. Prediksi parameter arus lalu lintas secara real-time merupakan tantangan karena arus lalu lintas bersifat dinamis.

TCPS memberikan peluang untuk mengatasi tantangan ini dengan memungkinkan kendaraan untuk menyiarkan Pesan Keselamatan Dasar (BSM). Dalam TCPS, BSM mencakup data lintasan (yaitu, waktu, lokasi, kecepatan, akselerasi). Standar Society of Automotive Engineers, SAE J2735, telah mendefinisikan format dan elemen BSM. Estimasi dan prediksi parameter arus lalu lintas waktu nyata dari BSM memerlukan penyertaan variasi temporal dan spasial data, yang dapat ditangani secara efektif melalui model DL. Model-model ini menangkap nonlinieritas pola lalu lintas. RNN dalam menangkap variasi temporal dan spasial serta memprediksi data deret waktu dengan tingkat akurasi yang tinggi. RNN dalam telah digunakan untuk memprediksi volume lalu lintas.

Prediksi Perilaku Pengemudi

Pemodelan perilaku pengemudi berbasis ML dalam populer di kendaraan otonom. Model-model ini dapat digunakan untuk menangkap pola mengemudi manusia menggunakan data lintasan. Model mengikuti mobil berbasis DL telah menunjukkan akurasi tinggi dalam menangkap pola pergerakan longitudinal pengemudi manusia. Ada dua aspek penting dari model ini: (1) kalibrasi parameter yang bergantung pada skenario mengemudi; dan (2) pelatihan model dengan data yang memadai untuk berbagai kemungkinan skenario mengemudi, termasuk situasi yang tidak terduga. RL dalam atau pembelajaran terawasi telah menunjukkan kemampuan untuk mengurangi kebutuhan data pelatihan dan meningkatkan kemampuan belajar dalam skenario yang tidak terduga. Model pelacakan mobil berbasis ML dapat memanfaatkan data pergerakan longitudinal terkait skenario mengemudi tak terduga untuk membuat keputusan yang lebih baik, yang perlu dibahas dalam studi mendatang.

Pengenalan Visual dalam TCPS

Metode DL umumnya digunakan untuk tugas pengenalan visual, seperti mengenali rambu kendaraan, pejalan kaki, dan lalu lintas. Misalnya, kendaraan otonom menggunakan sensor visual, seperti kamera, untuk merasakan lingkungan sekitar dan memanfaatkan model DL untuk mendeteksi objek di sekitar kendaraan. Model CNN umumnya digunakan untuk pengenalan visual. Untuk aplikasi waktu nyata (real-time), R-CNN, Faster R-CNN, atau YOLOv3 dapat digunakan.

Berdasarkan akurasi deteksi visual, YOLOv3 menunjukkan kinerja yang unggul dengan sekitar 20 bingkai per detik, melampaui model DL canggih lainnya. Kinerja real-time model DL diperlukan untuk sistem di dalam kendaraan dan aplikasi yang berfokus pada infrastruktur transportasi. Dengan tersedianya perangkat yang mendukung pemrosesan GPU yang lebih tinggi, akurasi dan waktu komputasi model DL meningkat untuk aplikasi TCPS.

Aplikasi untuk Perusahaan Jaringan Transportasi dan Transportasi Umum

Metode pembelajaran berbasis pembelajaran (DL) telah digunakan untuk memprediksi rute optimal bagi perusahaan jaringan transportasi (TNC) dan layanan transportasi umum dengan mempertimbangkan permintaan lalu lintas. Model DL telah menunjukkan kemampuannya dalam menangkap fitur spasial, temporal, dan eksogen. Fitur-fitur ini penting untuk memprediksi permintaan penumpang. Misalnya, jaringan LSTM konvolusional dalam (FCL-Net) telah dikembangkan dengan mempertimbangkan variabel spasiotemporal (yaitu, intensitas permintaan historis, waktu tempuh), dan variabel deret waktu nonspasial (yaitu, hari dalam seminggu, waktu dalam sehari, cuaca). FCL-Net digunakan untuk memprediksi rute optimal menggunakan dataset catatan taksi Kota New York.

Selain itu, TNC perlu meminimalkan waktu tunggu dan biaya penumpang dengan memodifikasi jadwal rute pengemudi untuk menjemput penumpang. Penelitian terbaru menunjukkan model pembelajaran penguatan mendalam (deep reinforcement learning) mampu menyarankan rute terbaik kepada pengemudi TNC dengan mempertimbangkan lokasi kendaraan saat ini, waktu, dan persaingan antar pengemudi. Model DRL ini membantu mengurangi waktu idle kendaraan TNC dan memastikan pendapatan jangka panjang bagi pengemudi.

Peningkatan Keamanan Siber TCPS

Infrastruktur siber transportasi, seperti sinyal lalu lintas yang terhubung, infrastruktur data pinggir jalan, dan infrastruktur cloud, merupakan bagian integral dari kota pintar. Namun, sistem infrastruktur siber transportasi yang rumit dan sangat terhubung rentan terhadap kegagalan yang meluas akibat serangan siber, yang mengakibatkan dampak yang menghancurkan, seperti pelanggaran data perusahaan dan pribadi, gangguan pada kinerja sistem dan kendaraan, dan pada akhirnya membahayakan keselamatan publik.

Serangan siber pada sistem transportasi yang terhubung dan otomatis dapat mengakibatkan konsekuensi yang fatal. Misalnya, penyerang dapat mengakses sistem kendali kendaraan yang terhubung dan sinyal lalu lintas serta menyebabkan kecelakaan multi-kendaraan yang dahsyat. Karena sejumlah besar data tersedia dari berbagai sensor dalam sistem transportasi yang terhubung, model DRL dalam TCPS dapat mempelajari ancaman dan melindungi dari serangan keamanan siber. Namun, karena serangan keamanan siber bersifat dinamis, deteksi dan mitigasi ancaman siber secara real-time untuk sistem transportasi terhubung merupakan tugas yang menantang.

Model DL, seperti jaringan saraf rekuren dalam (DRL) dan pembelajaran penguatan mendalam (DRL), memiliki aplikasi yang luas dalam keamanan jaringan komunikasi, keamanan dalam kendaraan, dan keamanan infrastruktur. Jaringan saraf rekuren dalam (DRL) dapat mempelajari variasi temporal dan spasial data dan memprediksi perilaku yang tidak biasa untuk deteksi ancaman. Selain itu, karena kemampuan adaptasi dan kegunaannya dalam lingkungan real-time dan adversarial, DRL menunjukkan kesesuaian yang sangat baik untuk aplikasi keamanan siber di mana serangan siber semakin canggih.

14.8 KESIMPULAN

Sistem siber-fisik transportasi (TCPS) akan menjadi arus utama dalam setiap aspek sistem transportasi multimoda dengan kemajuan infrastruktur digital, yang terdiri dari teknologi penginderaan, komputasi, dan komunikasi. DL akan menjadi bagian integral dari TCPS untuk mendukung analitik yang terkait dengan berbagai aplikasi keselamatan, mobilitas, dan lingkungan. TCPS harus mencakup sistem manusia dan sosial dalam konsepsi, perencanaan, desain, operasi, dan manajemennya.

Dengan demikian, DL harus menjadi transparan untuk melayani setiap manusia dan masyarakat serta memberikan mobilitas, keselamatan, dan manfaat lingkungan yang setara bagi semua. Algoritma DL harus dapat dijelaskan, sehingga karakteristik dan tujuan yang melekat tidak berada dalam kotak hitam. Karena DL akan memainkan peran utama dalam TCPS, DL harus dapat dipercaya oleh semua pemangku kepentingan, seperti pengguna, penyedia sistem transportasi, dan vendor. Salah satu aspek penting dalam membangun kepercayaan adalah melindungi DL dalam TCPS.

Serangan adversarial terhadap TCPS merupakan ancaman yang dapat membahayakan keselamatan dan privasi semua pemangku kepentingan. Oleh karena itu, sangat penting untuk melindungi program DL yang berada di berbagai komponen TCPS, seperti infrastruktur, kendaraan, dan perangkat informasi pribadi. Keberhasilan integrasi DL dalam TCPS akan bergantung pada pembangunan pembelajaran mesin yang tepercaya, adil, dan efektif.

BAB 15

KECERDASAN BUATAN DALAM INDUSTRI KONSTRUKSI

15.1 PENDAHULUAN

Konstruksi merupakan salah satu industri global terbesar dan memiliki dampak besar tidak hanya pada pertumbuhan ekonomi dan pembangunan perkotaan, tetapi juga pada lingkungan dan kesejahteraan masyarakat yang tinggal, bekerja, dan bepergian di dalam dan di antara berbagai bagian lingkungan binaan. Dengan 7,4 juta karyawan, mewakili hampir 5% dari keseluruhan angkatan kerja, konstruksi merupakan salah satu sektor terbesar dalam perekonomian AS. Pada tahun 2019, total pengeluaran konstruksi mencapai sekitar Rp19.500 triliun, atau sekitar 6,3% dari PDB negara.

Pasar konstruksi global diprediksi akan tumbuh pada tingkat 4,2% dan mencapai sekitar Rp157.500 triliun pada tahun 2023. Khususnya, konstruksi perumahan diperkirakan berkembang lebih pesat karena urbanisasi dan pertumbuhan penduduk yang pesat. Permintaan untuk konstruksi ramah lingkungan, perumahan terjangkau, desain dan prefabrikasi digital, serta material baru seperti komposit polimer yang diperkuat serat juga meningkat.

Meskipun proyeksi menunjukkan tanda-tanda masa depan yang cerah bagi industri ini, berbagai hambatan besar diperkirakan akan memperlambat modernisasi praktik konstruksi tradisional di abad ke-21. Misalnya, dibandingkan dengan industri lain seperti manufaktur dan layanan kesehatan, industri konstruksi terus mengalami pertumbuhan produktivitas tenaga kerja yang lambat.

Selain itu, konstruksi merupakan salah satu industri yang paling kurang terdigitalisasi, yang berkontribusi terhadap tingginya volume limbah yang dihasilkan dan hilangnya sumber daya akibat penyimpangan dari rencana dan pengerjaan ulang. Faktanya, angka-angka menunjukkan bahwa hanya sekitar 30% dari semua proyek konstruksi yang selesai sesuai perkiraan anggaran dan waktu. Sebuah studi terhadap 258 proyek transportasi dari 20 negara berbeda mengungkapkan bahwa 9 dari 10 proyek mengalami pembengkakan biaya. Lebih lanjut, penyakit, cedera, dan kematian yang sering terjadi akibat pekerjaan telah menjadikan industri ini rumah bagi beberapa pekerjaan paling berbahaya di AS dan secara global.

Lanskap pekerjaan konstruksi di masa depan tetap berubah. Kemajuan pesat dalam teknik komputasi, pengetahuan teknik dan proyek, serta teknologi sensor merevolusi banyak praktik yang ada saat ini dan menempatkan industri kembali pada jalur disrupsi besar. Menurut McKinsey Global Institute (2017), produktivitas tenaga kerja konstruksi berpotensi meningkat dua kali lipat melalui penerapan teknologi baru seperti pemodelan informasi bangunan (BIM), pencetakan 3D, realitas virtual dan tertambah (VR/AR), internet untuk segala (IoT), dan robotika. Selain itu, mereka yang terlibat dalam penelitian ilmiah tingkat lanjut mengantisipasi bahwa proses konstruksi generasi mendatang akan menghadirkan peluang baru untuk kolaborasi antara manusia dan mesin cerdas.

Untuk mewujudkannya, manusia dan mesin harus mendelegasikan tugas dan berbagi tanggung jawab. Dalam kebanyakan kasus, meskipun tugas berisiko tinggi atau rutin akan dilakukan oleh robot otonom, untuk tugas-tugas yang menuntut secara kognitif, robot akan bekerja sama dengan manusia untuk memaksimalkan produktivitas dan kualitas pekerjaan, sekaligus meminimalkan biaya, waktu penyelesaian, dan risiko operasional. Untuk mencapai tujuan ini, bidang penelitian dan praktik yang sedang berkembang semakin banyak memanfaatkan visi komputer dan kecerdasan buatan (AI) karena keberhasilannya yang telah terbukti dalam berbagai aplikasi dunia nyata di berbagai domain, misalnya, mendeteksi objek sehari-hari, mengembangkan mobil tanpa pengemudi, dan menganalisis citra medis.

15.2 KESELAMATAN KONSTRUKSI

Konstruksi merupakan pekerjaan berbahaya, yang ditandai dengan tingginya angka kecelakaan dan cedera di tempat kerja. Pada tahun 2016–2017, dibandingkan dengan semua industri lain di AS, jumlah total kecelakaan kerja fatal tertinggi terjadi di sektor konstruksi. Pada tahun 2018, industri ini menyumbang 21% dari seluruh kematian pekerja di sektor swasta AS. Selain itu, pada tahun 2019, kematian di industri konstruksi swasta meningkat sebesar 5% menjadi total 1.061, yang merupakan angka tertinggi sejak tahun 2007.

Administrasi Keselamatan dan Kesehatan Kerja (OSHA) telah mengidentifikasi empat penyebab utama kematian di sektor konstruksi yang bertanggung jawab atas hampir 60% dari seluruh kematian pekerja. Penyebab-penyebab ini secara kolektif disebut "empat fatal" dan meliputi jatuh, tertimpa benda, tersengat listrik, dan terjepit/di antara benda. Industri ini juga sering mengalami penyakit dan cedera yang tidak fatal di antara para pekerjanya. Seiring dengan semakin kompleks dan menantang proyek konstruksi, para pekerja di berbagai bidang seringkali harus melampaui batas fisik alami mereka saat melakukan tugas berulang dalam jangka waktu yang lama.

Tuntutan fisik yang berkelanjutan pada tubuh pekerja terbukti menyebabkan masalah kesehatan dan cedera fisik, yang disebut gangguan muskuloskeletal (MSD). Selain implikasi fisik dan psikologis yang merugikan, MSD juga dapat menyebabkan kerugian finansial yang signifikan. Misalnya, total kerugian finansial akibat MSD diperkirakan mencapai sekitar Rp750 triliun per tahun di AS.

Gangguan Muskuloskeletal Akibat Kerja (WMSD) dan Pencegahan melalui Desain (Ptd)

Gangguan muskuloskeletal akibat kerja (WMSD) mengacu pada MSD yang disebabkan oleh aktivitas yang dilakukan di tempat kerja. Pekerjaan konstruksi manual melibatkan aktivitas seperti menangani dan mengangkat benda berat, memutar tubuh, dan postur tubuh yang tidak nyaman, yang semuanya merupakan kontributor utama WMSD. Jenis WMSD yang paling umum dalam konstruksi adalah keseleo, tegang otot, sindrom terowongan karpal (CTS), tendonitis, dan nyeri punggung. Pada tahun 2019 saja, 231 dari setiap 10.000 pekerja konstruksi mengalami cedera akibat WMSD di AS.

Pada tahun yang sama, jumlah total kasus WMSD yang dilaporkan adalah 19.790 dengan median 11 hari tidak bekerja. Statistik ini dan statistik serupa memberikan gambaran sekilas tentang hilangnya produktivitas dalam konstruksi akibat WMSD. Pencegahan melalui

Desain (PtD), sebuah inisiatif yang diperkenalkan oleh Institut Nasional untuk Keselamatan dan Kesehatan Kerja (NIOSH), mengacu pada antisipasi dan perancangan bahaya terkait ergonomi dalam fasilitas, metode kerja, operasi, proses, peralatan, perkakas, produk, teknologi baru, dan organisasi kerja (NIOSH, 2014). Tujuan utama PtD adalah meminimalkan WMSD dengan mencegah dan membatasi cedera, penyakit, dan kematian akibat kerja.

Menurut NIOSH, hal ini dapat dicapai dengan: (1) menghilangkan atau mengurangi potensi risiko bagi pekerja ke tingkat yang dapat diterima di sumbernya atau sedini mungkin dalam siklus hidup proyek; (2) mencakup perancangan, perancangan ulang, dan perbaikan tempat kerja, struktur, perkakas, fasilitas, peralatan, mesin, produk, zat, proses kerja, dan organisasi kerja yang baru dan yang sudah ada; dan (3) meningkatkan lingkungan kerja melalui integrasi metode pencegahan dalam semua desain yang memengaruhi pekerja dan orang lain.

OSHA mengidentifikasi delapan faktor risiko yang dapat menyebabkan WMSD, termasuk penggunaan tenaga yang berlebihan, pengulangan, postur yang tidak nyaman, postur statis, gerakan cepat, tekanan kompresi atau kontak, getaran, dan suhu ekstrem (OSHA, 2000). Dengan mengikuti prinsip-prinsip PtD, faktor-faktor risiko ini dapat dihilangkan dengan menata ulang tempat kerja dan/atau memilih alat yang tepat untuk pekerja.

Namun, pekerjaan yang berbeda menimbulkan jenis dan besaran risiko yang berbeda, sehingga menambah tingkat kesulitan dalam mengidentifikasi risiko ergonomis yang terkait dengan pekerjaan tertentu. Meskipun analisis bahaya pekerjaan yang menyeluruh dapat mengidentifikasi risiko di tempat kerja, analisis tersebut mungkin sulit dilakukan karena kompleksitas pekerjaan dan upaya manual yang diperlukan untuk memantau proses kerja di lokasi kerja.

Fatal Four dan Persyaratan Alat Pelindung Diri (APD)

Pada tahun 2017, "fatal four" bertanggung jawab atas 59,8% dari seluruh 971 kematian pekerja konstruksi. Khususnya, jatuh merupakan penyebab paling sering, mencapai 39,2% (391 kasus) dari seluruh kematian, sementara tertimpa benda, tersengat listrik, dan terjepit/terjepit merupakan akar penyebab dari 8,2% (80 kasus), 7,3% (71 kasus), dan 5,1% (50 kasus) dari seluruh 971 kematian, masing-masing. Apa pun penyebabnya, sebagian besar insiden ini dapat dicegah jika pekerja mengenakan APD yang sesuai, misalnya helm keselamatan, rompi keselamatan, sarung tangan, kacamata keselamatan, dan sepatu baja.

Faktanya, OSHA, dan lembaga serupa di belahan dunia lain mewajibkan semua personel yang bekerja di dekat bahaya lokasi untuk mengenakan APD yang tepat agar meminimalkan risiko terpapar atau terluka oleh bahaya. Secara khusus, para peneliti dan praktisi menekankan pada penggunaan helm pengaman yang benar untuk meminimalkan cedera dan kematian. Misalnya, antara tahun 2003 dan 2010, total 2.210 kematian konstruksi (25% dari semua kematian konstruksi) terjadi karena cedera otak traumatis (TBI). Penyebab paling umum untuk kematian ini termasuk jatuh dari ketinggian, jatuhnya benda di kepala, dan sengatan listrik oleh kabel yang menjorok. Mengingat hal ini, OSHA mewajibkan pekerja untuk mengenakan helm pengaman ketika ada benda di atas kepala, atau jika ada kemungkinan kepala pekerja terbentur benda, atau secara tidak sengaja bersentuhan dengan sumber listrik yang menggantung.

Rompi keselamatan merupakan komponen APD penting lainnya yang dapat meminimalkan risiko cedera. Misalnya, tertabrak benda dapat terjadi karena lalu lintas di lokasi kerja atau alat berat (misalnya, truk, bulldoser, grader) yang beroperasi di dekat pekerja. Oleh karena itu, untuk memastikan visibilitas tinggi dalam segala kondisi pencahayaan dan cuaca, OSHA mewajibkan pekerja mengenakan rompi keselamatan (umumnya berwarna merah atau oranye, dan reflektif jika karyawan bekerja di malam hari).

Meskipun terdapat ketentuan ini, terdapat persentase yang cukup besar dari pekerja konstruksi yang gagal mematuhi langkah-langkah keselamatan industri. Penelitian telah mengidentifikasi akar penyebab ketidakpatuhan ini sebagai kurangnya kesadaran, ketidaknyamanan mengenakan APD, dan perasaan bahwa APD mengganggu pekerjaan atau tugas seseorang di lokasi kerja. Misalnya, tidak menggunakan APD yang tepat (yaitu, pelindung mata dan wajah) adalah salah satu peraturan yang paling banyak dilanggar pada tahun 2017–2018. Undang-undang yang mengatur dan peraturan keselamatan hampir selalu meminta pertanggungjawaban pemberi kerja untuk menegakkan, memantau, dan memelihara APD yang sesuai di tempat kerja. Untuk menegakkan kepatuhan terkait APD di lokasi kerja, OSHA mendenda pemberi kerja dengan mengenakan penalti untuk setiap karyawan yang gagal mematuhi persyaratan APD.

Dalam periode 12 bulan yang berakhir pada September 2018, OSHA mengeluarkan 895 surat tilang karena tidak mengenakan helm pengaman (total denda ≈ Rp28,7 miliar) dan 78 surat tilang karena melanggar persyaratan APD lainnya (total denda ≈ Rp4,6 miliar) di lokasi konstruksi. Beban kompensasi tersebut seringkali dibebankan kepada perusahaan dan/atau karyawan karena perusahaan asuransi tidak menanggung kerugian apa pun yang disebabkan oleh praktik APD yang tidak tepat.

15.3 TEKNIK PENGUMPULAN DATA

Tempat kerja yang aman tidak hanya membutuhkan identifikasi faktor risiko yang tepat waktu, tetapi juga pengambilan tindakan yang tepat untuk menghilangkan atau membatasinya. Untuk mencapai tujuan ini, data yang relevan dan andal harus dikumpulkan dari lapangan untuk pemantauan keselamatan pekerja secara berkelanjutan. Data ini juga membantu tim manajemen keselamatan untuk membuat keputusan yang tepat guna secara proaktif mencegah insiden yang tidak diinginkan yang mungkin terjadi akibat praktik yang tidak aman. Secara umum, terdapat tiga pendekatan berbeda untuk pengumpulan data, yaitu penilaian diri, berbasis observasi, dan pengukuran langsung.

Pendekatan Penilaian Diri

Dalam pendekatan penilaian diri, data dikumpulkan melalui buku harian pekerja, laporan diri, wawancara, dan kuesioner. Misalnya, Li dkk. (2017) mensurvei 445 pekerja konstruksi di Tiongkok untuk mengevaluasi persepsi mereka tentang keselamatan konstruksi. Gerdle dkk. (2008) mewawancarai 9.952 partisipan di Swedia melalui kuesioner pos untuk mempelajari pengaruh status kerja terhadap nyeri anatomi. Campo dkk. (2008) mensurvei 882 partisipan AS pada WMSD, dan Östergren dkk. (2005) mempelajari 4.919 orang di Swedia untuk mengkorelasikan faktor fisik dan psikologis terkait pekerjaan dengan nyeri bahu dan

leher. Baru-baru ini, para peneliti juga telah memanfaatkan kuesioner berbasis video dan web untuk mengumpulkan data penilaian diri.

Misalnya, Sunindijo dan Zou (2012) mengumpulkan pendapat 353 personel konstruksi tentang pentingnya soft skills untuk manajemen keselamatan konstruksi melalui survei daring berbasis web. Meskipun pendekatan penilaian diri sederhana, pendekatan ini sering kali menambah biaya pengumpulan data, terutama dalam kasus yang menginginkan ukuran sampel besar, serta memerlukan keterampilan khusus untuk menganalisis dan menginterpretasikan hasil. Lebih lanjut, penelitian sebelumnya telah menunjukkan bahwa penilaian diri pekerja mungkin tidak tepat, tidak andal, dan bias. Misalnya, Balogh dkk. (2004) menemukan bahwa untuk tingkat paparan yang sama (misalnya, aktivitas fisik) terhadap WMSD, pekerja yang memiliki keluhan nyeri tubuh sebelumnya (selama 12 bulan terakhir) melaporkan paparan yang jauh lebih tinggi, dibandingkan dengan mereka yang tidak memiliki keluhan sebelumnya.

Pendekatan Berbasis Observasi

Dalam pendekatan berbasis observasi, data dikumpulkan oleh seorang inspektur ahli yang secara sistematis mengevaluasi aktivitas di lokasi kerja. Misalnya, Teschke dkk. (2009) menggunakan pengamat terlatih untuk menilai postur pekerja konstruksi dalam studi epidemiologi gangguan punggung. Namun, pendekatan ini bersifat disruptif, terutama ketika data harus dikumpulkan secara langsung (real-time) dengan kehadiran fisik di lokasi kerja (David, 2005). Salah satu cara untuk mengatasi masalah ini adalah dengan menganalisis rekaman video aktivitas di lokasi kerja. Sebagai contoh, dalam sebuah studi oleh Dartt dkk. (2009), dua pengamat terlatih memperkirakan postur anggota tubuh bagian atas pekerja manufaktur dari dua video yang disinkronkan (masing-masing merekam pandangan bidang sagital dan frontal pekerja).

Keunggulan utama metode observasi berbasis video dibandingkan metode observasi langsung adalah video dapat dianalisis beberapa kali untuk meminimalkan variabilitas intra-pengamat (yaitu, ketidaksepakatan antar-pengamat di antara pengukuran yang dilakukan oleh individu yang sama). Namun, metode ini mungkin rentan terhadap variabilitas antar-pengamat (yaitu, ketidaksepakatan antar-pengamat di antara pengukuran yang dilakukan oleh individu yang berbeda) dan mungkin tidak praktis karena memerlukan biaya, waktu, dan pelatihan teknis yang substansial.

Pendekatan Pengukuran Langsung

Dalam pendekatan pengukuran langsung, berbagai perangkat periferal digunakan untuk mengumpulkan data secara langsung dari pekerja atau ruang kerja untuk analisis selanjutnya. Contohnya antara lain penggunaan identifikasi frekuensi radio (RFID), unit pengukuran inersia (IMU), sensor ponsel pintar, kamera RGB, kamera RGB-D (informasi visual plus kedalaman), deteksi dan pengukuran jarak laser (LADAR), serta deteksi dan pengukuran jarak cahaya (LiDAR).

Sebagai contoh, penggunaan tag RFID dapat diterapkan pada pekerja atau peralatan untuk pelokalan dan pelacakan waktu nyata di lokasi konstruksi yang kompleks. Sistem berbasis RFID juga dapat dimanfaatkan untuk memantau penghuni tetap dan bergerak di

dalam gedung. Selain itu, RFID dapat dipasang pada APD (misalnya, helm, rompi keselamatan, kaca mata keselamatan) yang dikenakan oleh pekerja sehingga dapat dilacak secara otomatis ketika pekerja memasuki lokasi konstruksi. Sensor yang dikenakan di pergelangan tangan telah digunakan untuk mengukur tingkat kenyamanan termal penghuni. Sistem berbasis IMU yang dapat dikenakan (misalnya, akselerometer, giroskop) juga telah dikembangkan untuk mendeteksi pekerja besi yang hampir jatuh, serta digunakan untuk mengumpulkan data kinematik tentang gerakan pekerja dan gaya berjalan guna mencegah penyakit dan cedera terkait pekerjaan.

Selain itu, data IMU dapat dimanfaatkan untuk mengenali aktivitas peralatan konstruksi. Baru-baru ini, ponsel pintar telah berkembang menjadi alat pengumpulan data yang menjanjikan karena keberadaannya di mana-mana, kemudahan penggunaan, dan adanya IMU bawaan bersama sensor lain seperti kamera, GPS, magnetometer, dan barometer. Sebagai contoh, sensor ponsel pintar digunakan untuk menganalisis postur pekerja konstruksi dan memantau aktivitas yang berisiko menimbulkan kelelahan berlebih. Ponsel pintar yang dipasang pada tubuh juga dimanfaatkan untuk memprediksi lintasan pergerakan pekerja guna mencegah tabrakan dengan peralatan yang bergerak. Selain itu, sensor ponsel pintar telah dipakai untuk memantau aktivitas pekerja konstruksi sekaligus aktivitas peralatannya.

Pendekatan pengukuran langsung juga dapat memanfaatkan data gambar atau video (visual) yang ditangkap oleh kamera RGB. Berbeda dengan observasi berbasis video, pendekatan ini menggunakan sistem otomatis dengan keterlibatan manusia yang minimal. Misalnya, data visual dari kamera RGB dapat digunakan untuk mengenali APD pekerja konstruksi, mendeteksi keberadaan pagar pengaman di lokasi kerja, menganalisis perilaku tidak aman pekerja saat menaiki tangga, atau melacak pergerakan pekerja dan peralatan untuk mencegah kecelakaan tabrakan. Sistem penangkapan gerak berbasis penanda juga dapat dipakai untuk membangun model kerangka 3D pekerja konstruksi dari bingkai video guna memantau perilaku tidak aman.

Lebih lanjut, sensor kedalaman yang terintegrasi dengan kamera RGB (kamera RGB-D) dapat dipakai untuk mengumpulkan data yang lebih detail dari lokasi kerja. Contohnya, Microsoft Kinect digunakan untuk menganalisis perilaku memanjat pekerja yang tidak aman serta mengevaluasi postur pekerja konstruksi. Selain itu, teknologi LADAR dan LiDAR juga digunakan untuk mengumpulkan data dengan mendeteksi kedalaman menggunakan cahaya. Untuk meningkatkan kesadaran di tempat kerja, LADAR dapat dimanfaatkan untuk mendeteksi dan melacak sumber daya konstruksi (pekerja, peralatan, material) secara waktu nyata (real-time). Namun, kamera kedalaman biasanya terbatas pada penggunaan di dalam ruangan karena akurasinya yang rendah di bawah sinar matahari terang dan jangkauan kerja yang relatif pendek. Meskipun demikian, secara umum, pendekatan pengukuran langsung mampu menghasilkan data yang sangat akurat dibandingkan pendekatan lain. Perlu dicatat bahwa investasi awal untuk membeli dan memelihara sistem pengukuran langsung, serta keahlian teknis yang dibutuhkan untuk menganalisis data, bisa sangat tinggi.

Kecerdasan Buatan (AI) untuk Analisis Data

Untuk menganalisis sejumlah besar data multi-moda kompleks yang dikumpulkan, menggunakan satu atau lebih metode di atas, berbagai metode statistik dan komputasi telah diusulkan. Metode-metode ini meliputi penambangan data (misalnya, regresi, pengenalan pola, pengelompokan), visi komputer (klasifikasi gambar, deteksi objek, pelacakan objek, segmentasi semantik dan instans), penambangan teks, analisis spasio-temporal, dan pemrosesan bahasa alami (NLP).

Beberapa metode ini dibangun di atas kemampuan algoritma untuk secara efektif mengidentifikasi dan memproses informasi informatif (alias fitur) dalam data mentah menggunakan serangkaian aturan dan/atau instruksi yang telah diketahui sistem sebelumnya (alias dikodekan secara manual) atau dapat ditemukan melalui pelatihan pada data yang diinginkan. Kategori algoritma pertama umumnya disebut heuristik, sementara yang kedua merupakan fondasi kecerdasan buatan (AI). Mengingat cakupan bab ini, dalam paragraf-paragraf berikut, ikhtisar beberapa teknik AI yang umum disajikan. Pembahasan ini diikuti dengan deskripsi aplikasi domain yang relevan di bagian selanjutnya.

Pembelajaran Mesin (ML)

Ketika sebuah mesin, tanpa diprogram secara eksplisit, belajar dari pengalamannya (E) untuk melakukan tugas tertentu (T), istilah *pembelajaran mesin* (*machine learning* / ML) mengacu pada kemampuan mesin untuk secara konsisten meningkatkan kinerjanya (P) pada tugas T setelah pengalaman E. Dalam ML, secara umum, tugas tersebut dapat berupa regresi (dengan data masukan menghasilkan nilai kuantitatif yang kontinu), klasifikasi (menetapkan data masukan ke dalam kategori diskrit), atau pengelompokan (mempartisi data masukan ke dalam beberapa kelompok berbeda).

Pendekatan ML secara umum dapat dibagi menjadi dua kategori:

- ✓ **Pembelajaran terawasi** (*supervised learning*), yaitu belajar dari contoh-contoh yang diberikan.
- ✓ **Pembelajaran tak terawasi** (*unsupervised learning*), yaitu membagi kumpulan data masukan dengan cara yang bermakna.

Tugas regresi dan klasifikasi termasuk dalam kategori pertama, sedangkan pengelompokan termasuk kategori kedua. Contoh algoritma pembelajaran mesin terawasi yang umum meliputi: regresi linier, regresi logistik, Naive Bayes, pohon keputusan, hutan acak, *support vector machine* (SVM), dan *k-nearest neighbor* (kNN). Di sisi lain, pengelompokan *k-means*, analisis komponen utama (PCA), dan dekomposisi nilai singular (SVD) merupakan contoh teknik pembelajaran mesin tak terawasi.

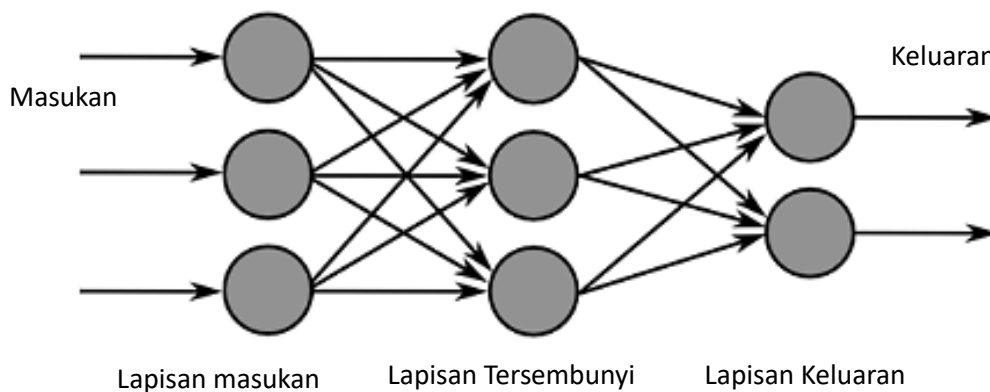
Di antara semua model ML, jaringan saraf tiruan (NN / JST) telah banyak diadopsi karena kemampuannya mempelajari fungsi nonlinier yang kompleks. Ide NN berasal dari neurobiologi, di mana jaringan ini meniru otak manusia yang terdiri dari neuron dan koneksi sinaptik.

Secara umum, NN memiliki tiga jenis lapisan:

1. **Lapisan masukan** (*input layer*)
2. **Lapisan tersembunyi** (*hidden layer*)

3. Lapisan keluaran (*output layer*)

Masing-masing lapisan berisi sejumlah neuron (*node*). Setiap neuron pada lapisan tersembunyi maupun keluaran secara independen menerima masukan dari lapisan sebelumnya dengan bobot tertentu (w). Setelah diproses dengan fungsi aktivasi $f(x)$, hasilnya diteruskan ke neuron pada lapisan berikutnya. Proses berurutan dari lapisan ke lapisan ini dikenal sebagai *forward pass*. Pada akhirnya, neuron di lapisan keluaran menghasilkan hasil akhir, misalnya nilai riil untuk masalah regresi atau label kelas untuk masalah klasifikasi. Selama fase pelatihan, bobot w dalam NN diperbarui dengan algoritma *backpropagation* untuk meminimalkan fungsi biaya (atau kerugian) L .



Gambar 15.1: Diagram skema jaringan saraf tiruan.

Selain dua skema pembelajaran tradisional (yaitu, terawasi dan tak terawasi), terdapat juga teknik pembelajaran mesin lainnya, termasuk pembelajaran mendalam, pembelajaran semi-terawasi, pembelajaran aktif, pembelajaran penguatan, pembelajaran adversarial, dan pembelajaran imitasi. Beberapa metode ini dijelaskan di bagian berikut karena kasus penggunaannya yang baru-baru ini berhasil dalam domain konstruksi.

Pembelajaran Mendalam (DL)

Pembelajaran mendalam (*Deep Learning/DL*) merupakan cabang dari pembelajaran mesin (*Machine Learning/ML*) yang memanfaatkan jaringan saraf tiruan (*Neural Network/NN*) dengan arsitektur lebih kompleks untuk menyelesaikan berbagai tugas yang rumit, seperti visi komputer, pemrosesan audio, dan pemrosesan bahasa alami (*NLP*). Beberapa arsitektur DL yang banyak digunakan meliputi jaringan saraf dalam (*Deep Neural Network/DNN*), yaitu NN dengan banyak lapisan, serta jaringan saraf berulang (*Recurrent Neural Network/RNN*), yaitu NN dengan blok memori yang memungkinkan pemrosesan data sekuensial. Namun demikian, salah satu arsitektur DL yang paling populer adalah jaringan saraf konvolusional (*Convolutional Neural Network/CNN*), yang sangat luas digunakan dalam permasalahan visi komputer untuk menganalisis data berupa gambar maupun video.

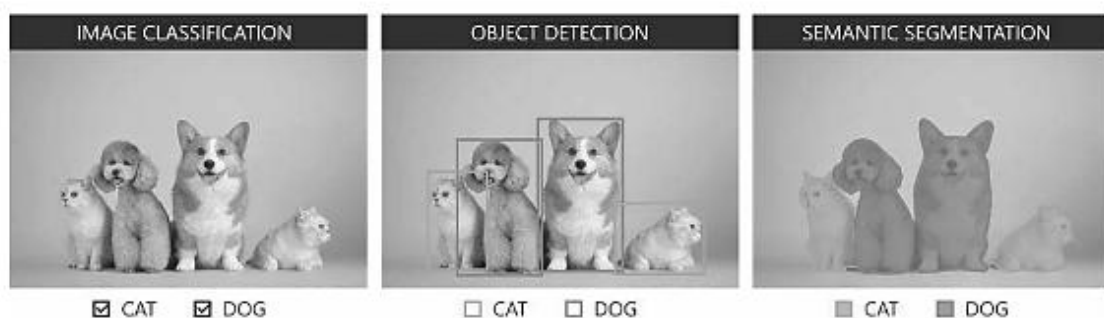
Secara umum, CNN terdiri atas beberapa lapisan utama, yaitu lapisan konvolusional, lapisan normalisasi batch, lapisan penggabungan (*pooling*), serta lapisan yang terhubung penuh. Popularitas CNN didorong oleh kemampuannya dalam mengekstraksi fitur secara otomatis dari kumpulan data tanpa selalu membutuhkan daya komputasi yang berlebihan.

Perkembangan CNN berawal dari sistem sederhana yang mampu mengenali digit tulisan tangan, hingga model modern yang dapat mengklasifikasikan ribuan kategori objek berbeda seperti hewan, benda sehari-hari, maupun peralatan teknis. Beberapa arsitektur CNN yang dikenal luas antara lain VGG-16, ResNet-50, dan Xception.

Dalam bidang visi komputer, CNN umumnya diterapkan untuk tiga kategori utama tugas, yaitu klasifikasi gambar, deteksi objek, dan segmentasi semantik. Klasifikasi gambar merujuk pada proses mengklasifikasikan keseluruhan gambar ke dalam satu atau beberapa kelas, sementara deteksi objek berkaitan dengan pelokalan objek-objek tertentu di dalam gambar dengan menggunakan kotak pembatas (bounding box) sekaligus mengidentifikasi kelas objek tersebut. Segmentasi semantik, berbeda dari dua tugas sebelumnya, berfokus pada penentuan setiap piksel dalam gambar yang termasuk dalam kelas tertentu.

Karena kompleksitas deteksi objek, dikembangkan berbagai varian CNN berbasis wilayah (Region-based CNN/R-CNN) yang mampu meningkatkan kinerja. R-CNN pertama kali menggunakan pencarian selektif untuk mengidentifikasi wilayah yang berpotensi berisi objek, kemudian mengekstraksi fitur menggunakan CNN, dan selanjutnya mengklasifikasikan objek dengan SVM. Akan tetapi, metode ini membutuhkan sumber daya komputasi yang sangat besar. Perbaikan dari pendekatan ini kemudian menghasilkan Fast R-CNN yang lebih efisien, dan selanjutnya Faster R-CNN yang menambahkan komponen Region Proposal Network (RPN) untuk menghasilkan kandidat wilayah secara lebih cepat.

Mask R-CNN kemudian dikembangkan sebagai varian yang memperluas Faster R-CNN dengan cabang tambahan yang mampu menghasilkan segmentasi semantik berupa masker dengan bentuk tidak beraturan, sehingga lebih detail dalam mengidentifikasi objek. Selain itu, terdapat pula R-FCN (Region-based Fully Convolutional Network) yang menghilangkan kebutuhan lapisan fully connected yang mahal secara komputasi, sehingga dapat mempercepat proses deteksi sambil tetap menjaga akurasi.



Gambar 15.2: Klasifikasi citra, deteksi objek, dan segmentasi semantik.

Metode berbasis proposal wilayah mendeteksi objek menggunakan beberapa jaringan, yang masing-masing dirancang untuk menjalankan subtugas tertentu. Sebaliknya, algoritma you-only-look-once (YOLO) dan single shot multibox detector (SSD) menggabungkan tugas klasifikasi dan lokalisasi menjadi satu NN tunggal yang secara signifikan mengurangi beban komputasi. Perbandingan kinerja berbagai algoritma yang dilakukan oleh Liu dkk. (2016)


menunjukkan bahwa hanya algoritma YOLO yang dapat melakukan deteksi objek secara real-time, yaitu lebih dari 30 bingkai per detik (FPS).

Jaringan Adversarial Generatif (GAN)

Jaringan adversarial generatif (Generative Adversarial Network/GAN) merupakan kerangka kerja dalam pembelajaran mesin yang dirancang untuk menghasilkan data baru dari suatu input tertentu. Secara internal, model GAN terdiri dari dua jaringan yang bekerja secara independen, yaitu generator (G) dan diskriminator (D). Peran generator (G) adalah menghasilkan data buatan (Y_G) yang diharapkan tidak dapat dibedakan dari data nyata (Y_R). Sebaliknya, diskriminator (D) bertugas membedakan secara tepat apakah data yang diberikan berasal dari Y_G atau Y_R .

Dalam proses pelatihan, kedua jaringan ini berkompetisi untuk meningkatkan kinerjanya masing-masing. Generator berupaya menghasilkan Y_G yang semakin realistis sehingga diskriminator tidak mampu membedakannya dari data nyata, sementara diskriminator berusaha memperbaiki kemampuannya dalam menemukan perbedaan sekecil apa pun antara Y_G dan Y_R agar generator tidak dapat menipunya.


Dinamika persaingan antara kedua jaringan tersebut dapat dipandang sebagai permainan *minimax* dalam perspektif teori permainan, di mana generator dan diskriminator berperan sebagai dua agen yang berhadapan. Permainan berakhir ketika masing-masing agen mencapai tingkat kompetensi minimum yang secara bersamaan dianggap maksimum oleh agen lawan. Melalui proses yang dikenal sebagai pelatihan adversarial, diskriminator pada akhirnya mampu membedakan dengan baik data nyata dan data hasil generator meskipun keduanya sangat mirip, sedangkan generator belajar menghasilkan data sintetis yang sangat realistis sehingga sulit dibedakan dari data sebenarnya.



Gambar 15.3: Diagram skema model GAN.

Pembelajaran Penguatan (RL)

Pembelajaran penguatan (*Reinforcement Learning/RL*), yang merupakan cabang lain dari pembelajaran mesin, adalah metode coba-coba untuk mempelajari perilaku yaitu menentukan tindakan apa yang harus diambil dalam situasi tertentu melalui interaksi berkelanjutan dengan lingkungan. Contoh penerapannya antara lain sistem AlphaGo yang belajar memainkan permainan Go, robot otonom yang belajar berjalan sendiri, serta mobil swakemudi yang belajar mengemudi di jalan raya.



Gambar 15.4: Diagram skematis proses RL.

Dalam permasalahan RL, pembelajar sering disebut sebagai agen. Segala sesuatu di sekitar agen yang dapat berinteraksi dengannya disebut lingkungan. Pada waktu tertentu, bagian lingkungan yang dapat diakses oleh agen dapat dideskripsikan dalam bentuk matematika yang disebut keadaan lingkungan. Seperti ditunjukkan pada Gambar 15.4, agen RL dapat melakukan tindakan untuk mengubah keadaan lingkungan. Dengan melakukan tindakan tersebut, agen menerima umpan balik dari lingkungan yang menunjukkan manfaat tindakan tersebut dalam mencapai tujuan pembelajaran akhir dari permasalahan. Umpan balik ini dideskripsikan dalam bentuk numerik dan disebut imbalan.

Perlu dicatat bahwa RL pada dasarnya berbeda dari teknik pembelajaran terawasi yang umum digunakan. Dalam pembelajaran terawasi, misalnya, mesin belajar dari serangkaian data pelatihan yang diberi label oleh seorang supervisor (misalnya, anotator manusia). Namun, dalam RL, agen secara aktif mencari data pelatihan (yaitu, status dan imbalan) di lingkungan yang tidak diberi label. Dalam praktiknya, RL dapat dianggap sebagai pembelajaran daring karena tidak semua data pelatihan tersedia sekaligus. Agen RL menjelajahi lingkungan dan mengumpulkan data pelatihan. Dalam setiap iterasi pelatihan, agen hanya mempertimbangkan data pelatihan yang tersedia hingga saat itu.

15.4 APLIKASI AI DALAM KONSTRUKSI

Kasus Penggunaan yang Berhasil dengan Implikasi Praktis; Memantau Risiko Ergonomis dan Produktivitas Kru

Sebagaimana dinyatakan sebelumnya, pekerja konstruksi semakin terpapar risiko ergonomis yang kemudian menyebabkan WMSD. Salah satu sumber utama WMSD adalah postur canggung saat melakukan aktivitas padat karya. Untuk memantau risiko ergonomis pekerja yang terkait dengan postur canggung, seperti yang ditunjukkan pada Gambar 15.5(a), Nath dkk. (2017) mengusulkan pemasangan ponsel pintar pada tubuh pekerja dan memanfaatkan sensor IMU bawaan untuk mengukur postur secara diam-diam dan mengidentifikasi potensi risiko ergonomi terkait pekerjaan secara otomatis.

Pendekatan yang murah dan mudah diterapkan ini telah divalidasi melalui eksperimen, dan hasilnya menunjukkan bahwa pengukuran fleksi batang tubuh dan bahu pekerja sangat mendekati pengukuran ground truth yang diperoleh melalui observasi berbasis video. Metode ini tidak hanya berlaku untuk pekerja konstruksi (misalnya, buruh, tukang kayu, tukang las, operator material), tetapi juga pekerja lapangan dan karyawan di berbagai pekerjaan lain

(misalnya, petani, asisten kesehatan, guru, dan pekerja kantor) yang secara teratur terpapar WMSD akibat postur yang tidak nyaman.



Gambar 15.5: Pengenalan postur canggung (a) dan aktivitas berlebihan (b) menggunakan ponsel pintar yang terpasang di badan.

Serupa dengan postur canggung, aktivitas berlebihan (yaitu, mengerahkan tenaga berlebihan untuk melakukan suatu aktivitas) dapat menyebabkan WMSD parah dalam jangka panjang. Oleh karena itu, dalam studi lain, Nath dkk. (2018) menggunakan ponsel pintar yang terpasang di badan untuk mengenali aktivitas yang terlalu berat (misalnya, mendorong, menarik, mengangkat, membawa, memuat, membongkar) di lokasi konstruksi.

Khususnya, seperti yang ditunjukkan pada Gambar 15.5(b), data deret waktu yang dikumpulkan dari sensor ponsel pintar yang dikenakan di badan (akselerometer, giroskop) dianalisis menggunakan algoritma ML tradisional (misalnya, SVM) untuk mengenali aktivitas pekerja dalam interval waktu 3 detik. Selanjutnya, dengan menggabungkan prediksi untuk interval waktu yang lebih panjang, informasi frekuensi dan durasi setiap aktivitas diukur. Informasi ini digunakan bersama dengan ketentuan OSHA untuk mengukur risiko ergonomi yang terkait dengan aktivitas berlebihan. Lebih lanjut, durasi aktivitas yang teridentifikasi memberikan wawasan tentang produktivitas kru dan dapat digunakan untuk membuat model simulasi kejadian diskret guna mengoptimalkan alur kerja, mengalokasikan sumber daya, dan merancang tata letak lokasi.

Pengambilan Konten dari Data Visual

Data visual merupakan salah satu modalitas data yang paling umum untuk merekam dan mendokumentasikan pekerjaan lapangan konstruksi. Foto dan video sering digunakan dalam laporan kemajuan, permintaan informasi (RFI), pelatihan keselamatan, pemantauan produktivitas, serta klaim dan litigasi. Data visual juga dapat dimanfaatkan untuk menghasilkan titik awan dan merekonstruksi elemen bangunan dalam bentuk 3D.

Dalam beberapa aplikasi, kemunculan kecerdasan buatan telah memungkinkan analisis otomatis data visual untuk pengukuran volumetrik material, pelacakan pekerja dan sumber daya, pemantauan keselamatan kerja, dan pengenalan material konstruksi. Maraknya kamera digital, perangkat seluler seperti ponsel pintar dengan konektivitas internet, serta kendaraan

udara nirawak (drone) yang dilengkapi kamera internal telah meningkatkan ukuran dan kualitas data visual yang dikumpulkan setiap hari secara eksponensial. Misalnya, diperkirakan 1,43 triliun gambar diambil pada tahun 2020, jumlah ini 43% lebih banyak dibandingkan dengan gambar yang diambil pada tahun 2018.

Di lokasi konstruksi, sejumlah besar data visual dikumpulkan setiap hari. Sebagai contoh, lebih dari 400.000 gambar dikumpulkan selama pembangunan fasilitas komersial dengan luas 750.000 kaki persegi. Penelitian lain mencatat lebih dari 100.000 gambar berhasil dihimpun dari 25 lokasi konstruksi hanya dalam periode satu tahun. Ketika diproses dan diberi anotasi dengan tepat, data visual yang besar ini dapat membantu meningkatkan akurasi dan ketepatan waktu pengambilan keputusan dalam proyek konstruksi.

Namun, gambar yang diambil sering kali tidak mengandung metadata yang kaya selain informasi dasar seperti tanggal, waktu, dan dalam beberapa kasus geolokasi. Oleh karena itu, pencarian konten visual tertentu dari sejumlah besar gambar dapat berubah menjadi tugas yang rumit dan memakan banyak sumber daya. Salah satu solusi potensial untuk tantangan ini adalah membuat struktur semantik untuk kumpulan gambar dengan menggunakan tag metadata yang mendeskripsikan konten, misalnya objek atau pemandangan, serta tampilan, seperti warna atau konteks.

Dalam pengenalan pola dan pembelajaran mesin, proses pembuatan tag metadata otomatis untuk data visual menggunakan model kecerdasan buatan disebut pengambilan konten gambar. Untuk melatih model pengambilan konten, sebuah dataset internal bernama Pictor-v1 telah dikembangkan yang berisi sekitar 2.000 gambar objek umum terkait konstruksi, misalnya bangunan yang sedang dibangun, peralatan konstruksi, truk, bulldoser, ekskavator, derek, dan pekerja konstruksi. Dengan melatih model CNN berbasis VGG-16, sistem berhasil menetapkan satu atau beberapa label, seperti bangunan, peralatan, dan pekerja untuk setiap gambar.

Khususnya, pembelajaran transfer digunakan untuk melatih model CNN, di mana model awalnya dilatih pada dataset ImageNet yang besar dengan jutaan gambar, kemudian dilatih ulang atau disempurnakan pada dataset Pictor-v1. Hasilnya, model yang telah dilatih berhasil menetapkan label kelas tunggal dengan akurasi sekitar 90% dan beberapa label kelas dengan akurasi sekitar 85%.



Gambar 15.6: Contoh klasifikasi citra konstruksi dan deteksi objek (*himpunan data citra dapat diakses di <https://github.com/ciber-lab>*).

Deteksi Objek Konstruksi

Seperti yang ditunjukkan pada Gambar 15.6, dibandingkan dengan klasifikasi citra, deteksi objek memberikan informasi yang lebih kaya secara semantik, seperti jumlah objek yang diminati, dan hubungan spasial di antara objek-objek tersebut, yang dapat dimanfaatkan untuk pengambilan konten yang lebih akurat. Deteksi objek dengan fidelitas tinggi menguraikan dasar pemahaman pemandangan dengan membantu mengekstrak deskriptor informatif (misalnya, jenis, warna, posisi) dari masing-masing objek dalam pemandangan. Nath dan Behzadan (2020a) mengembangkan Pictor-v2, sebuah himpunan data visual yang terdiri dari sekitar 2.500 citra dengan anotasi tingkat instans objek terkait konstruksi (misalnya, bangunan, peralatan, dan pekerja). Khususnya, himpunan data tersebut berisi citra yang diperoleh dari penambangan web (diambil melalui internet) dan crowdsourcing (dikumpulkan dari lokasi konstruksi). Secara umum, gambar yang ditambang web terstruktur dengan baik dan memiliki kecerahan dan kontras yang baik.

Namun, mereka mungkin juga berisi latar belakang yang dimanipulasi atau efek visual pasca-proses lainnya. Di sisi lain, gambar crowdsourced, meskipun memiliki daya tarik visual yang lebih rendah, mungkin berisi lebih banyak informasi spesifik konstruksi dunia nyata. Oleh karena itu, untuk menyelidiki pengaruh faktor-faktor ini, model YOLO dilatih dan diuji pada berbagai kombinasi dataset Pictor-v2 (yaitu, ditambang web, crowdsourced, atau gabungan) dengan hasil yang menunjukkan bahwa model cenderung berkinerja lebih baik pada gambar uji yang secara visual seperti gambar pelatihan.

Subset Pelatihan	YOLO-v2			YOLO-v3		
	Crowdsourced	Webmined	Gabungan	Crowdsourced	Webmined	Gabungan
Crowdsourced	52.1	46.7	48.5	72.5	53.6	61.1
Webmined	36.9	62.5	52.3	50.8	70.0	62.3
Gabungan	59.6	65.0	62.6	78.2	76.6	77.3

Gambar 15.7: Rata-rata presisi (%) model YOLO-v2 dan YOLO-v3 dalam mendeteksi objek terkait konstruksi, ketika dilatih dan diuji pada citra crowdsourced dan citra web.

Misalnya, seperti yang ditunjukkan pada Gambar 15.7, ketika sebuah model dilatih hanya pada gambar yang ditambah web, ia berkinerja sangat baik ketika diuji pada gambar yang ditambah web, dan kinerjanya menurun ketika model yang sama diuji pada gambar yang ditambah crowdsourced. Ini juga mengungkapkan jebakan utama dalam melatih model AI; Karena citra hasil penambangan web relatif lebih mudah dan cepat dikumpulkan, mungkin lebih mudah untuk melatih dan menguji model hanya pada citra hasil penambangan web dan mengharapkan kinerja yang serupa ketika model ini diuji dalam skenario dunia nyata.

Model tersebut berkinerja sangat buruk dalam skenario tersebut, seperti yang ditunjukkan pada Gambar 15.7. Untuk mengatasi masalah ini, Nath dan Behzadan (2020a) mengusulkan untuk menggunakan kombinasi citra hasil penambangan web dan citra crowdsourced. Investigasi mereka menyimpulkan bahwa model tersebut, ketika dilatih pada kumpulan data gabungan, berkinerja baik pada kumpulan data hasil penambangan web dan crowdsourced dan menunjukkan akurasi yang lebih tinggi pada setiap subset pengujian dibandingkan dengan kasus di mana model dilatih hanya pada kumpulan data hasil penambangan web atau crowdsourced (Gambar 15.7).

Verifikasi Kepatuhan APD

Dalam aplikasi konstruksi lainnya, para peneliti telah menggunakan kecerdasan buatan untuk memantau kepatuhan pekerja terhadap pedoman alat pelindung diri (APD) secara otomatis dan waktu nyata. Penelitian sebelumnya umumnya menggunakan model komputasi yang mahal seperti R-CNN atau model terlatih untuk mendeteksi hanya satu jenis APD, terutama helm keselamatan. Sebaliknya, penelitian yang lebih baru merancang kerangka kerja komprehensif untuk memantau kepatuhan pekerja terhadap pedoman APD secara otomatis dengan mendeteksi dua komponen APD sekaligus, misalnya helm keselamatan dan rompi keselamatan, beserta warnanya.

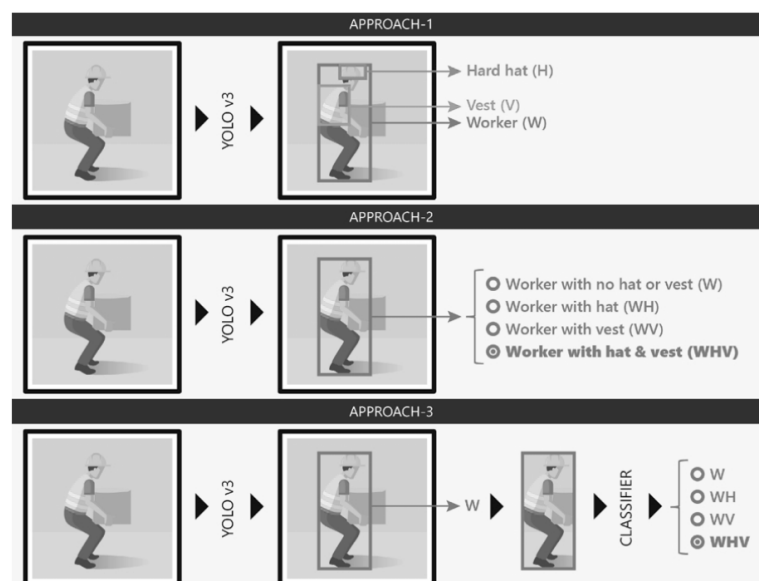
Untuk melatih dan menguji model kecerdasan buatan, dataset Pictor-v3 yang berisi sekitar 1.500 gambar beranotasi dan sekitar 4.700 contoh pekerja dengan berbagai kombinasi komponen APD dikembangkan. Beberapa pendekatan kemudian diuji untuk memverifikasi kepatuhan APD. Dalam Pendekatan-1, model berbasis YOLO-v3 mendeteksi pekerja dan berbagai jenis APD secara individual, misalnya helm pengaman dan rompi keselamatan. Namun, deteksi individual ini tidak memiliki hubungan kontekstual antara objek yang terdeteksi. Oleh karena itu, algoritma pembelajaran mesin tambahan, seperti pohon keputusan, diterapkan untuk memverifikasi apakah setiap pekerja yang terdeteksi benar-benar mengenakan salah satu APD yang terdeteksi.

Dalam Pendekatan-2, model berbasis YOLO-v3 lainnya dirancang untuk melokalisasi pekerja dan langsung mengklasifikasikan mereka berdasarkan pakaian APD yang dikenakan. Kelas klasifikasi terdiri atas: tidak mengenakan helm pengaman maupun rompi keselamatan (W), hanya helm pengaman (WH), hanya rompi keselamatan (WV), serta helm pengaman dan rompi keselamatan sekaligus (WHV). Meskipun pendekatan ini lebih sederhana, model menunjukkan kebingungan yang lebih tinggi antar kelas karena keempat kategori tersebut secara visual mirip, yaitu sama-sama berisi orang.

Dalam Pendekatan-3, hanya pekerja yang dideteksi dan dipotong dari gambar, terlepas dari pakaian APD yang dikenakan. Potongan gambar pekerja tersebut kemudian dimasukkan ke algoritma berikutnya untuk memverifikasi pakaian APD. Untuk ini, berbagai pengklasifikasi CNN dilatih untuk mengklasifikasikan pekerja ke dalam salah satu dari empat kelas: W, WH, WV, dan WHV. Hasil penelitian menunjukkan bahwa penerapan model ansambel Bayesian, yang menggabungkan prediksi dari beberapa CNN seperti VGG-16, ResNet-50, dan Xception, mampu menghasilkan akurasi yang lebih baik.

Selain itu, pendekatan inovatif lain dikembangkan untuk tidak hanya mendeteksi jenis komponen APD tetapi juga warnanya dengan akurasi tinggi. Motivasi khusus dalam mengenali warna APD adalah karena di lokasi konstruksi aturan kode warna sering digunakan untuk membedakan peran, jenis pekerjaan, atau hak akses. Dengan demikian, kemampuan untuk mengidentifikasi warna APD dapat memberikan wawasan tambahan tentang jenis aktivitas yang berlangsung di lokasi tertentu sekaligus membantu memantau keamanan di lapangan.

Secara khusus, teknik berbasis kesamaan digunakan, yaitu dengan membandingkan gambar kueri seorang pekerja dengan pakaian APD yang tidak diketahui dengan gambar galeri pekerja lain yang pakaiannya sudah diketahui. Dari gambar galeri yang paling cocok, pakaian APD beserta warnanya kemudian diprediksi untuk pekerja yang dimaksud. Teknik ini berhasil mendeteksi pakaian APD dengan akurasi sekitar 90% dan mengenali warna komponen APD dengan akurasi sekitar 77%.



Gambar 15.8: Tiga pendekatan untuk memverifikasi kepatuhan pekerja terhadap APD.



Gambar 15.9: Identifikasi komponen APD (helm dan rompi keselamatan) dan warnanya berdasarkan ukuran kesamaan.


Tantangan Utama dalam Mengembangkan Model DL dan Solusi Potensial

Tantangan pertama dalam mengembangkan model DL yang robust untuk aplikasi konstruksi adalah sifat dinamis dan kompleksitas lokasi konstruksi, yang berarti bahwa data visual yang ditangkap dari lokasi-lokasi ini bersifat intermiten dan beragam secara visual. Misalnya, ketika dilihat dalam beberapa gambar, objek yang sama mungkin muncul dalam berbagai ukuran, pada jarak yang berbeda dari kamera, dan/atau terhalang oleh objek lain. Oleh karena itu, untuk lebih memahami pengaruh kualitas data terhadap kualitas pengenalan visual, kinerja model DL untuk gambar yang diambil dalam kondisi visual yang berbeda harus diperiksa dan di-benchmark secara cermat.

Tujuan ini, Nath dan Behzadan (2019) membagi instans objek dalam dataset Pictor-v2 menjadi dua kategori 'lebih kecil' jika ukurannya lebih kecil dari ukuran median semua objek, dan 'lebih besar' jika sebaliknya. Selain itu, lokasi konstruksi umumnya terdiri dari ruang yang padat dan pemandangan yang terhalang yang dapat menghambat kemampuan model untuk menemukan objek yang diinginkan secara akurat. Untuk mengukur kepadatan visual dalam sebuah gambar, Nath dan Behzadan (2019) selanjutnya membagi contoh objek dalam dataset Pictor-v2 menjadi kelompok 'lebih padat' dan 'kurang padat'.

Jika kotak pembatas suatu objek tumpang tindih secara signifikan dengan kotak pembatas objek lain (yaitu, irisan atas gabungan, $IoU > 0\%$), objek tersebut dianggap 'lebih padat'. Lebih lanjut, gambar yang diambil di lokasi konstruksi dengan pencahayaan redup mungkin tidak mengandung informasi yang kaya konten (karena kecerahan dan kontras yang

lebih rendah). Jumlah informasi yang berguna dalam sebuah gambar dapat diukur dengan entropi Shannon. Objek yang memiliki entropi Shannon lebih besar dari nilai median untuk semua objek ditandai sebagai 'terang baik', dan semua objek lainnya dianggap 'terang buruk'. Dengan skema pengelompokan ini, ditemukan bahwa model YOLO-v3 berkinerja jauh lebih baik dalam mendeteksi objek besar.



Gambar 15.10: Contoh gambar beresolusi rendah, gambar yang dihasilkan GAN, dan gambar beresolusi tinggi yang sesuai.

Khususnya, untuk mendeteksi pekerja, presisi dan perolehan kembali model mencapai 98%, menunjukkan akurasi yang mendekati tingkat manusia. Selain itu, model ini berhasil mendeteksi objek yang tidak terlalu ramai dan terang benderang dengan lebih akurat.

Tantangan kedua dalam mengembangkan model DL yang robust untuk aplikasi konstruksi adalah kualitas data visual yang diambil oleh perangkat penangkap gambar. Umumnya, semua algoritma berbasis penglihatan (termasuk deteksi objek) berkinerja lebih baik ketika kualitas gambar masukan tinggi. Misalnya, para peneliti telah mencapai hasil yang lebih baik dalam mengenali wajah dalam gambar dan mengambil informasi biologis dari gambar medis dengan menggunakan gambar berkualitas lebih tinggi

Namun, fakta bahwa proyek konstruksi sering kali berlangsung di lingkungan yang keras dapat menghambat kemampuan untuk mengumpulkan citra berkualitas baik dan terang

benderang, yang pada gilirannya, dapat secara signifikan menurunkan kinerja model DL, seperti yang dilaporkan oleh Nath dan Behzadan (2019) dan Hendrycks dan Dietterich (2019). Oleh karena itu, dalam studi lain, Nath dan Behzadan (2020c) mengusulkan teknik peningkatan citra berbasis AI yang secara khusus menggunakan GAN untuk meningkatkan resolusi citra demi deteksi objek yang cepat dan andal. Seperti ditunjukkan pada Gambar 15.10, model GAN dilatih untuk meningkatkan resolusi citra masukan (resolusi rendah) sebanyak 4 kali lipat di setiap dimensi (lebar dan tinggi). Dengan demikian, informasi yang hilang pada piksel perantara digantikan dengan informasi sintetis berkualitas tinggi.

Selanjutnya, dua model YOLO-v3 yang telah dikembangkan sebelumnya diaplikasikan pada citra yang dihasilkan GAN untuk mengukur kualitas deteksi objek ketika dilakukan pada citra yang disempurnakan. Khususnya, satu model YOLO-v3 dilatih pada dataset Pictor-v2 untuk mendeteksi objek konstruksi umum, yaitu bangunan, peralatan, dan pekerja, sebagaimana dijelaskan sebelumnya. Model YOLO-v3 lainnya dilatih pada dataset Pictor-v3 untuk mendeteksi pekerja dan APD, misalnya, helm pengaman (H) dan rompi keselamatan (V), yang juga dijelaskan di bagian sebelumnya. Hasil penelitian menunjukkan bahwa untuk resolusi masukan yang bervariasi, kedua model berkinerja 4%–21% lebih baik dalam mendeteksi objek ketika citra masukan ditingkatkan oleh model GAN.

Tantangan ketiga dalam mengembangkan model DL yang robust untuk aplikasi konstruksi adalah ketergantungan metode yang telah disebutkan sebelumnya untuk deteksi objek dan pemantauan keselamatan pada visibilitas objek yang diinginkan dalam pemandangan. Masalah oklusi visual merupakan salah satu hambatan paling umum terhadap keberhasilan pengenalan visual. Misalnya, dalam studi sebelumnya, penurunan signifikan (2%–7%) dalam kinerja pengenalan wajah diamati ketika wajah tertutup sebagian.

Ketika model DL digunakan untuk pemantauan keselamatan, kepatuhan APD pekerja mungkin tidak dapat diverifikasi dengan kepastian tinggi dari sudut pandang kamera tertentu karena ada bagian tubuh pekerja yang tetap tertutup oleh objek lain. Solusi sepele untuk masalah ini adalah mengunjungi kembali lokasi konstruksi dan mengambil gambar dari sudut pandang berbeda di mana pekerja tampak cukup terlihat. Namun, data yang dikumpulkan dari berbagai bagian lokasi konstruksi yang besar bersifat sementara, terutama ketika beberapa kru dan peralatan menempati dan bekerja di area yang sama secara bersamaan. Selain itu, ketika objek bergerak di depan satu sama lain dan sebagian menghalangi pandangan kamera, mungkin tidak layak untuk selalu mengumpulkan gambar bebas oklusi.

Selain memasang beberapa kamera, yang membutuhkan perawatan dan kalibrasi ekstensif, solusi potensialnya adalah mengembangkan sistem cerdas di mana kamera dengan kemampuan penglihatan aktif (yaitu, kemampuan untuk bernavigasi di tempat kejadian dan beroperasi secara otonom) mencari sudut pandang optimal untuk mengumpulkan data visual yang cukup baik dan bebas oklusi. Nath (2021) mendemonstrasikan kelayakan pendekatan ini dengan melatih kamera terbang berkemampuan AI (misalnya, yang dipasang pada drone) menggunakan RL, dan mengujinya dalam lingkungan simulasi untuk memvalidasi metode yang diusulkan.

Mereka menemukan bahwa mulai dari posisi awal yang dipilih secara acak, hampir 90% dari waktu, kamera mampu menemukan posisi di mana objek yang diinginkan (dalam hal ini, seorang pekerja konstruksi) terlihat lebih baik. Kerangka kerja ini berpotensi mendukung dan mendorong kolaborasi manusia-mesin di lokasi konstruksi dengan mendelegasikan tugas rutin pemantauan berkelanjutan terhadap kepatuhan keselamatan kepada robot otonom.

15.5 PERTIMBANGAN PENERAPAN AI DAN OTOMASI DALAM KONSTRUKSI

AI merevolusi dunia konstruksi dengan memimpin industri menuju otomasi dan alur kerja cerdas. Khususnya, penerapan AI dalam kolaborasi manusia-mesin di lokasi konstruksi diharapkan dapat menghasilkan ruang kerja yang lebih aman, kru yang lebih produktif, dan kualitas kerja yang lebih tinggi. Untuk mewujudkan potensi AI secara maksimal dan menguraikan pengetahuan teoretis untuk kolaborasi manusia-mesin yang sukses, para peneliti dan pengembang teknologi terkemuka cenderung berfokus pada robotika konstruksi. Di luar tantangan teknis (beberapa di antaranya telah dijelaskan dalam bab ini), terdapat beberapa pertimbangan praktis yang harus ditangani secara memadai agar teknologi ini dapat diterima dan diadopsi sepenuhnya oleh pengguna industri. Bagian ini membahas beberapa tantangan tersebut dan solusi potensial di masa depan konstruksi.

Penerimaan dan Adopsi Teknologi

Keberhasilan implementasi kemajuan teknologi baru di seluruh industri bergantung pada pertanyaan utama: akankah pekerja dan pimpinan perusahaan memercayai sistem baru ini? Praktisi konstruksi umumnya tidak percaya pada teknologi baru, dan mendapatkan dukungan manajemen, menyesuaikan alur kerja teknik yang sudah ada, serta membangun kepercayaan di antara para pekerja terbukti sangat sulit. Meskipun pengenalan teknologi baru merupakan upaya berkelanjutan, terdapat kebutuhan mendesak untuk mengidentifikasi infrastruktur psikologis yang tepat yang diperlukan untuk mengadopsinya dalam konstruksi. AI, khususnya, dianggap oleh banyak pengguna akhir sebagai 'kotak hitam' yang sebagian besar mengabaikan faktor-faktor kepercayaan seperti transparansi teknologi, keandalan, privasi dan keamanan, etika, dan elemen budaya, yang semuanya perlu ditangani dengan tepat sebelum solusi AI dapat diadopsi.

Robot, sebagai contoh lain, dapat mengurangi risiko keselamatan fisik sementara keselamatan psikologis tim pekerja-robot juga harus dipertimbangkan. Penting bagi pekerja untuk memandang robot sebagai rekan satu tim yang memungkinkan mereka bertransisi ke tugas-tugas tingkat tinggi, alih-alih sebagai orang luar yang menunggu untuk menyergap mereka demi pekerjaan mereka. Saat ini, teori yang terakhir lebih tersebar luas di kalangan pekerja perdagangan dan bukan di kalangan pimpinan perusahaan.

Tren Industri dan Munculnya Ekosistem Kewirausahaan 'Contech'

Saat ini, dalam industri konstruksi, teknologi jarang dikembangkan secara internal, dan tren yang umum adalah membeli produk siap pakai, atau melisensikannya dari atau bermitra dengan pengembang eksternal. Hal ini mengakibatkan munculnya perusahaan rintisan kecil namun berkembang pesat yang didirikan oleh para individu yang antusias dengan proposisi nilai berbasis AI yang memilih untuk berfokus pada konstruksi sebagai ceruk pasar.

Ekosistem yang relatif baru ini dikenal sebagai 'Contech' (Braesemann dan Baum, 2020) di komunitas wirausaha dan telah menjadi kabar baik bagi pemodal ventura yang dapat berinvestasi di perusahaan yang memasuki pasar yang menguntungkan mengingat tingginya kebutuhan akan teknologi untuk mempercepat durasi proyek, meningkatkan isu keselamatan dan produktivitas, serta menyediakan kapasitas prediktif untuk penawaran proyek atau pengukuran kinerja.

Sementara itu, perusahaan konstruksi juga telah merangkul kemitraan semacam itu karena mereka melihat keunggulan kompetitif yang dihasilkan. Model bisnis perusahaan Contech serupa dan sederhana (yaitu, aliran pendapatan berbasis langganan atau proyek) dan umumnya bekerja dengan baik dengan sistem arus kas yang unik dalam konstruksi. Hal ini sebagian disebabkan oleh tingginya penggunaan subkontraktor dalam konstruksi, yang merupakan model umum bagi kontraktor umum yang mereka adopsi untuk perusahaan rintisan Contech.

Robotika Kolaboratif Konstruksi melalui Pembelajaran Imitasi

Robot industri yang melakukan tugas-tugas penting namun membosankan bersama manusia merupakan hal pokok dalam fiksi ilmiah. Rosie si Robot dari Jetsons adalah model stereotip robot pembantu yang mampu memanipulasi objek secara otonom dan menyelesaikan tugas-tugas kompleks (Anderson dan Oates, 2007). Ada konsensus bahwa robot industri dengan kemampuan Rosie dapat menghemat waktu dan tenaga yang signifikan dari pekerja manusia.

Salah satu strategi untuk membuat robot otonom dan mampu memanipulasi adalah dengan memprogram mereka untuk mengikuti lintasan tertentu dan membuat kode keras pada sambungan mereka. Pendekatan ini layak untuk robot industri yang dikontrol posisinya dalam lini perakitan yang terstruktur dengan baik. Namun, sistem robotik seperti itu tidak dapat beradaptasi dengan lingkungan yang berubah seperti lokasi kerja konstruksi yang sangat dinamis dan tidak terstruktur. Di ruang kerja seperti itu, robot perlu memahami lingkungan dan benda kerjanya untuk menyesuaikan tugas manipulasinya. Ini mengharuskan robot untuk mempelajari tugas-tugas tersebut alih-alih diprogram untuk melakukannya. Sebagian besar proses konstruksi melibatkan tugas-tugas berulang yang terjadi di lingkungan yang kurang terstruktur dibandingkan dengan industri lain seperti manufaktur.

Oleh karena itu, robot konstruksi harus memahami lingkungannya dan mampu melakukan manipulasi tanpa diprogram sebelumnya untuk mengikuti lintasan tertentu. Yang membuat ini semakin rumit adalah bahwa dalam setiap tugas yang diberikan, mungkin ada jumlah skenario yang tak terbatas yang membuatnya hampir mustahil untuk memprogram sebelumnya atau membuat perintah eksplisit dan waktu nyata kepada robot yang tidak adaptif. Oleh karena itu, adaptasi terhadap pekerjaan, tempat kerja, dan cara pekerja melakukan sesuatu adalah kunci dalam robotika konstruksi.

Pendekatan pelatihan robot yang sedang tren yang memungkinkan adaptasi ini adalah pembelajaran dari demonstrasi (LfD) atau pembelajaran imitasi. Ide utama di balik LfD adalah agar robot mempelajari pekerjaan dengan mengamati demonstrasi suatu tugas. LfD setara dengan kerugian kloning perilaku dalam ruang pengkodean laten primer. Teknik ini

meningkatkan transfer pengetahuan dari pengguna (misalnya, pekerja konstruksi, supervisor) ke robot melalui cara alami demonstrasi sebagai pengganti metode lain seperti spesifikasi hadiah (misalnya, pembelajaran penguatan). Misalnya, Finn et al. (2017) mendemonstrasikan pendekatan pembelajaran meta-imitasi satu-shot di mana robot belajar menempatkan objek ke dalam wadah (baik objek maupun wadah sebelumnya tidak terlihat) hanya dari satu demonstrasi tunggal.

Dalam karya lain, Bonardi et al. (2020) menunjukkan bahwa robot dapat menyimpulkan gerakan tangan dengan menganalisis demonstrasi simulasi dan mempelajari gerakan baru (misalnya, menempatkan atau mendorong benda) dari satu demonstrasi di dunia nyata. Sieb (2019) menunjukkan bahwa robot dapat mempelajari gerakan tersebut hanya dengan mengamati manusia dalam video. Selain itu, Codevilla dkk. (2018) mendemonstrasikan pendekatan pembelajaran imitasi ujung ke ujung di mana kendaraan otonom belajar mengikuti jalan dan menghindari rintangan dengan meniru pengemudi manusia yang ahli.

Membangun Kepercayaan dan Kalibrasi

Kepercayaan merupakan perhatian penting dalam penerapan teknologi AI dan robotika dalam konteks apa pun. Penelitian terbaru tentang topik seperti AI yang dapat dijelaskan (XAI) dengan tujuan peningkatan transparansi yang substansial berawal dari perhatian ini dan membuktikan perlunya investigasi lebih lanjut. Konstruksi merupakan industri yang sangat sensitif dalam hal ini, dan menghadapi masalah sosio-teknis yang nyata terkait adopsi teknologi baru, terutama yang kurang transparan. Alasannya dapat diringkas sebagai berikut:

1. Industri konstruksi merupakan gabungan dari banyak usaha kecil: 82,3% lapangan kerja konstruksi dimiliki oleh usaha kecil (dibandingkan dengan manufaktur sebesar 44,4% dan ritel sebesar 35,1%), dan perusahaan kecil cenderung lebih lambat dalam mengadopsi teknologi.
2. Penggunaan subkontraktor yang tinggi: kurangnya konsistensi dalam adopsi teknologi mengharuskan pekerja untuk berpindah-pindah metode kerja yang berbeda ketika bekerja sebagai subkontraktor dari berbagai kontraktor umum yang memiliki praktik adopsi teknologi yang beragam. Adopsi teknologi di tempat kerja yang bertahap dan tidak konsisten dikenal sebagai pemicu stres karena meningkatnya kebingungan dan kesalahan yang diakibatkannya.
3. Konstruksi adalah industri berbasis penawaran kompetitif: margin keuntungan yang biasanya sangat kecil (yaitu, 3%–5%) membuat praktisi konstruksi lebih konservatif dalam menggunakan teknologi baru dengan keandalan yang belum teruji, jaminan privasi/keamanan, atau kinerja penghematan biaya.
4. Industri ini kekurangan pemimpin teknologi dan inovasi: seorang advokat industri terkemuka sering kali membuka jalan dan menunjukkan mengapa, kapan, dan bagaimana memanfaatkan teknologi. Di industri ritel, internet, atau otomotif terdapat Amazon, Google, dan Tesla, tetapi konstruksi tidak memiliki panutan seperti itu. Hal ini merupakan hambatan utama dalam menciptakan kepercayaan terhadap inovasi.

Dalam survei literatur terbaru, para peneliti mengidentifikasi transparansi dan keterjelasan, privasi dan keamanan, keselamatan dan keandalan, serta etika dan keadilan di antara

pendorong utama kepercayaan terhadap teknologi AI dan robotika. Mereka juga menyimpulkan bahwa elemen-elemen ini memainkan peran penting dalam menumbuhkan kepercayaan terhadap AI dan robotika di industri konstruksi, terlepas dari fase proyek, jenis proyek, tujuan aplikasi (misalnya, keselamatan, produktivitas), dan teknologi spesifik yang sedang dimanfaatkan (misalnya, BIM, blockchain).

Penelitian tentang topik penerimaan dan adopsi teknologi konstruksi, khususnya kecerdasan buatan (AI) dan robotika, masih sangat terbatas. Survei terhadap para profesional industri menunjukkan bahwa kurangnya pelatihan personel dan keengganan praktisi untuk menggunakan teknologi merupakan salah satu hambatan utama dalam adopsi teknologi, sementara aspek keselamatan, produktivitas, dan pemantauan kemajuan merupakan tiga area aplikasi teratas yang paling berpotensi mendapatkan manfaat dari integrasi teknologi berbasis data.

Sebagian besar penelitian sebelumnya mengenai penerimaan teknologi menyoroti hambatan dan pendorong adopsi hanya pada satu teknologi atau kemajuan tertentu, misalnya Building Information Modeling (BIM). Hasil riset implementasi BIM menunjukkan bahwa metrik kegunaan seperti persepsi kegunaan (PU) dan persepsi kemudahan penggunaan (PE) menjadi salah satu faktor anteseden kuat yang memengaruhi niat untuk mengadopsi teknologi dalam industri konstruksi. PU dan PE merupakan penentu utama sikap serta niat perilaku pengguna, dan keduanya menjadi konstruk inti dari model perilaku yang paling banyak digunakan dalam sistem informasi, yaitu model penerimaan teknologi (Technology Acceptance Model/TAM).

Model populer lainnya yang digunakan untuk menjelaskan penerimaan teknologi adalah ambang batas jaringan sosial (Social Network Threshold/SNT) dan teori difusi inovasi (Diffusion of Innovation/DoI). Meskipun model-model tersebut dimaksudkan sebagai kerangka generik dan konsisten, penelitian menunjukkan bahwa memperluas konstruk dengan faktor-faktor yang lebih spesifik sesuai domain, misalnya dalam konteks konstruksi, dapat menghasilkan model yang lebih relevan dan hasil yang lebih baik. Selain itu, penting untuk memperhatikan aspek keamanan psikologis dan konotasi negatif yang melekat pada istilah robotika maupun AI dalam konteks keamanan kerja di masa depan. Kehadiran robot berkemampuan AI yang bekerja berdampingan dengan pekerja konstruksi berpotensi menimbulkan ketegangan yang berdampak negatif pada kesehatan mereka. Lebih jauh lagi, meskipun membangun kepercayaan merupakan hal penting untuk meningkatkan adopsi, kepercayaan yang berlebihan maupun kepercayaan yang terlalu rendah terhadap AI sama-sama dapat berujung pada penyalahgunaan atau bahkan penolakan penggunaan teknologi tersebut.

Temuan dari aplikasi di dunia nyata maupun eksperimen skala laboratorium menunjukkan bahwa kedua kondisi ekstrem tersebut sangat umum terjadi. Proses menyesuaikan tingkat kepercayaan manusia agar selaras dengan keandalan sistem AI disebut kalibrasi kepercayaan. Penelitian memperlihatkan bahwa transparansi mengenai kemampuan AI dapat secara signifikan meningkatkan kemungkinan terciptanya kepercayaan yang lebih terkalibrasi sekaligus mendorong peningkatan tingkat adopsi. Dalam konteks konstruksi,

berbagai studi telah menegaskan bahwa nilai tambah yang dirasakan dari teknologi baru, baik dari sisi keamanan, efisiensi, maupun penghematan biaya dan waktu, memiliki pengaruh substansial terhadap tingkat penerimaan dan adopsinya.

Tenaga Kerja Masa Depan

Permintaan pekerjaan di sektor konstruksi, infrastruktur, dan bangunan terus meningkat seiring dengan kekurangan tenaga kerja serta tantangan penyediaan perumahan yang terjangkau. Permintaan baru ini diproyeksikan akan menciptakan puluhan hingga ratusan juta lapangan kerja pada tahun 2030. Namun, berbeda dengan sektor lain yang mengalami peningkatan pekerja lepas atau jarak jauh, pekerja konstruksi akan tetap bekerja secara kolaboratif dan di lokasi. Pekerja generasi mendatang, yakni Generasi Milenial dan Generasi Z, dikenal lebih melek teknologi dibandingkan tenaga kerja konstruksi saat ini yang sering dicirikan sebagai kurang menyukai teknologi. Sementara itu, tenaga kerja konstruksi yang ada cenderung semakin menua.

Data menunjukkan bahwa jumlah pekerja konstruksi berusia 55 tahun ke atas meningkat signifikan dalam beberapa tahun terakhir, sementara jumlah pekerja usia produktif utama (25–54 tahun) justru mengalami penurunan. Lembaga akademis terkemuka juga telah menyoroti adanya kesenjangan besar dalam ketersediaan tenaga kerja teknis dengan keterampilan yang memadai untuk bersaing di era modern. Kekurangan keterampilan ini dapat menimbulkan konsekuensi serius di lapangan, khususnya ketika pekerja ditugaskan menangani pekerjaan yang kompleks. Bahkan, statistik menunjukkan bahwa proporsi kecelakaan fatal di kalangan pekerja berusia 55 tahun ke atas meningkat tajam dalam beberapa dekade terakhir, sehingga menambah urgensi permasalahan ini. Dengan demikian, tantangan utama industri konstruksi mencakup dua hal: tenaga kerja saat ini yang menua sehingga perlu meningkatkan keterampilan, dan tenaga kerja generasi baru yang menuntut penerapan teknologi di tempat kerja agar pekerjaan konstruksi lebih menarik bagi mereka. Karena pekerja merupakan landasan produksi, maka mereka memegang peran penting dalam mendukung pertumbuhan industri konstruksi.

Oleh sebab itu, pengembangan serta peningkatan keterampilan tenaga kerja melalui pemanfaatan teknologi harus ditempatkan di garis depan upaya menghadapi tantangan besar industri. AI dan robotika perlu dirancang agar adaptif secara sosial terhadap alur kerja dan budaya teknologi yang telah ada di dunia konstruksi. Sebagai contoh, robot kolaboratif dituntut memiliki kecakapan sosial agar mampu berkoordinasi dengan anggota tim dalam melaksanakan rencana kerja bersama. Untuk mencapai hal ini, diperlukan landasan teoretis yang berakar pada ilmu sosial dan perilaku, seperti konsep aktivitas kooperatif bersama, niat bersama, serta landasan komunikasi yang sama. Pendekatan tersebut dapat membantu tercapainya tingkat ko-adaptasi yang dibutuhkan agar tenaga kerja konstruksi masa depan dapat lebih mudah mengadopsi teknologi AI.

15.6 KESIMPULAN

Meskipun menjadi salah satu industri global terbesar dan memiliki dampak besar terhadap perekonomian dunia, industri konstruksi mengalami pertumbuhan produktivitas

yang lambat. Selain itu, tingginya jumlah dan frekuensi penyakit, cedera, dan kematian telah mencirikan konstruksi sebagai salah satu pekerjaan paling berbahaya. Sebagai salah satu industri yang paling kurang terdigitalisasi, sebagian besar industri konstruksi tertinggal dalam mengadopsi teknologi baru. Lebih lanjut, meningkatnya masalah tenaga kerja yang menua mengharuskan upaya peningkatan keterampilan yang signifikan untuk melatih tenaga kerja yang kompetitif untuk abad ke-21. Untungnya, terdapat indikasi bahwa industri konstruksi akan terus berkembang pesat meskipun memiliki banyak kekurangan. Khususnya, teknologi baru (misalnya, BIM, pencetakan 3D, VR, AR, IoT, robotika) memegang kunci untuk merevolusi industri dan meningkatkan produktivitas serta keselamatan secara signifikan.

Lebih spesifik lagi, kolaborasi manusia-mesin berpotensi mendisrupsi industri dengan mereformasi praktik yang ada dan meningkatkan kualitas pekerjaan, yang pada akhirnya menghasilkan penghematan biaya dan waktu proyek, sekaligus membatasi risiko. Untuk mencapai tujuan ini, para peneliti dan praktisi semakin mengandalkan AI, visi komputer, dan robotika karena keberhasilannya yang luar biasa di bidang lain. Bab ini menyajikan narasi tentang keberhasilan penelitian penulis sebelumnya yang telah menunjukkan metode berbasis AI yang sangat efisien untuk meningkatkan keselamatan dan produktivitas konstruksi. Misalnya, teknik pembelajaran mesin (ML) digunakan untuk menganalisis data sensor ponsel pintar yang terpasang di tubuh guna mencegah risiko terkait WMSD di lokasi kerja. Selain itu, algoritma cepat berbasis pembelajaran mesin (DL) dirancang dan divalidasi untuk mengidentifikasi objek konstruksi umum secara real-time yang menjadi dasar pemahaman situasi oleh robot otonom.

Lebih lanjut, menyadari pentingnya penggunaan APD yang tepat (terutama helm pengaman dan rompi keselamatan) untuk mencegah cedera di lokasi kerja, metode pembelajaran mesin (DL) dirancang untuk memverifikasi kepatuhan pekerja terhadap APD secara real-time. Meskipun aplikasi AI ini telah menunjukkan potensi luar biasa untuk memantau keselamatan dan produktivitas pekerja secara otonom, tantangan utama juga diidentifikasi yang mungkin menghambat adopsi dan implementasi metode ini dalam praktik dalam skala besar. Misalnya, sifat dinamis dan kompleks lokasi konstruksi dapat membatasi kemampuan untuk mengumpulkan gambar berkualitas baik dan bebas oklusi untuk pengenalan visual.

Pertama, ditemukan bahwa model AI melakukan deteksi objek dengan lebih baik jika gambar berisi objek yang lebih besar (lebih dekat ke kamera), tidak terlalu ramai, dan terang benderang. Oleh karena itu, disarankan agar untuk mendapatkan hasil terbaik, kondisi visual yang serupa harus dipenuhi dalam praktik. Bahkan dalam kondisi tersebut, mungkin tidak memungkinkan untuk terus-menerus menangkap gambar berkualitas tinggi karena, misalnya, kondisi cuaca dan keterbatasan perangkat keras. Oleh karena itu, teknik berbasis GAN dikembangkan untuk meningkatkan kualitas gambar beresolusi rendah yang menghasilkan deteksi objek yang lebih baik. Selain itu, untuk mengatasi masalah oklusi, kamera otonom (dengan beberapa derajat kebebasan) dilatih melalui RL untuk melayang di lokasi konstruksi dan menemukan lokasi dari mana visibilitas objek yang diinginkan dapat dicapai dengan lebih baik.

Sementara para peneliti terus meletakkan fondasi teoretis untuk kolaborasi manusia-mesin yang sukses dalam konstruksi, terdapat beberapa tanggung jawab penting bagi para praktisi untuk secara efektif mempromosikan teknologi-teknologi mendatang ini di lokasi kerja. Bab ini membahas beberapa hambatan terpenting terhadap penerimaan dan adopsi penuh teknologi ini di lapangan. Pertama, kepercayaan terhadap AI perlu dibangun di antara para pemilik bisnis dan karyawan. Hal ini khususnya dapat dicapai dengan mempromosikan kegunaan dan kemudahan penggunaan teknologi AI dan menunjukkan manfaatnya secara nyata seperti penghematan biaya dan waktu serta pengurangan cedera terkait pekerjaan, serta melalui peningkatan transparansi dan kemudahan penjelasan, privasi dan keamanan, keselamatan dan keandalan, serta etika dan keadilan.

Lebih lanjut, pengembang AI (terutama perusahaan rintisan Contech yang memiliki hubungan kuat dengan industri dan serikat pekerja) harus maju untuk menjadikan diri mereka sebagai panutan bagi orang lain. Pada saat yang sama, tenaga kerja konstruksi perlu ditingkatkan keterampilannya untuk bekerja dengan teknologi baru dan dipersiapkan untuk mengadopsi AI dan robotika untuk konstruksi di masa depan. Pada akhirnya, dengan mempromosikan dan memungkinkan kemitraan manusia-mesin yang sukses dalam industri konstruksi, tempat kerja yang lebih aman dan produktif dapat terwujud, yang dapat memberikan manfaat sosial-ekonomi bagi pemberi kerja, karyawan, dan pemangku kepentingan.

BAB 16

PEMBELAJARAN MESIN UNTUK REKAYASA KEBAKARAN STRUKTURAL

16.1 PENDAHULUAN

Disiplin ilmu rekayasa kebakaran struktural (SFE) berkaitan dengan perancangan struktur yang aman dan efisien terhadap paparan termal akibat kebakaran di lingkungan internal maupun eksternal. Sebagian besar penilaian rekayasa kebakaran struktural biasanya terdiri dari 3 komponen: (1) Definisi skenario kebakaran dan kondisi termal yang disebabkan oleh kebakaran pada struktur, (2) Penilaian respons termal struktur akibat paparan api, dan (3) Penilaian respons mekanis sistem struktur akibat perambatan termal. Kompleksitas analisis masing-masing dari ketiga komponen ini akan bergantung pada tujuan penilaian. Terkait komponen kedua dari proses SFE, pemahaman yang akurat tentang bagaimana panas merambat melalui detail konstruksi ketika terpapar api memungkinkan insinyur untuk menentukan, antara lain:

- komponen mana yang kemungkinan mengalami degradasi termal pada sifat material,
- gradien termal dalam detail struktural dan oleh karena itu potensi lengkungan termal yang ditimbulkan,
- risiko penyalaan elemen yang mudah terbakar,
- kebutuhan spesifikasi proteksi kebakaran tambahan, dan
- peringkat klasifikasi detail konstruksi terhadap uji api standar.

Untuk menilai respons termal suatu detail konstruksi, biasanya diperlukan penyelesaian persamaan diferensial parsial perpindahan panas untuk geometri detail konstruksi yang diusulkan dan penggunaan kondisi batas yang sesuai. Ketika kompleksitas muncul seperti geometri non-simetris, sifat material yang bergantung pada suhu, berbagai mode perpindahan panas, dll., yang membuat penyelesaian persamaan mustahil dilakukan melalui skema numerik sederhana, penggunaan alat yang lebih canggih seperti Analisis Elemen Hingga (FEA) diperlukan dengan menggunakan paket perangkat lunak khusus.

Selama 20 tahun terakhir, telah terbukti bahwa metode FEA dapat memprediksi respons termal berbagai detail konstruksi secara akurat ketika terpapar api jika alat tersebut telah diverifikasi dan divalidasi dengan tepat untuk kondisi yang dipertimbangkan. Hasilnya, FEA telah diadopsi secara luas oleh komunitas teknik kebakaran struktural. Kelemahan utama analisis perpindahan panas berbasis FEA adalah membutuhkan waktu yang lama dan pengalaman khusus dalam komputasi numerik dibandingkan dengan menggunakan ekspresi analitis. Analisis detail konstruksi tipikal dapat memakan waktu antara beberapa menit hingga beberapa jam, tergantung pada ukuran geometri, kekasaran mesh, dan waktu simulasi. Selain itu, semua input harus ditentukan sebelum simulasi dimulai. Oleh karena itu, mengingat terdapat banyak jenis detail konstruksi yang mungkin terdapat dalam sebuah bangunan, dan detail tersebut dapat bervariasi dari satu proyek desain ke proyek desain lainnya, melakukan analisis FEA untuk setiap kasus desain akan menjadi tidak praktis. Hal ini juga akan

menimbulkan risiko dalam proses desain jika perubahan desain diperlukan sebelum simulasi FEA selesai.

Untuk mengatasi tantangan tersebut, diusulkan untuk menggunakan metodologi berbasis pembelajaran mesin untuk memprediksi respons termal menggunakan data dari analisis FEA yang telah dilakukan sebelumnya. Sistem yang diusulkan berfungsi sebagai model pengganti yang lebih efisien secara komputasi daripada simulasi FEA yang lengkap. Hal ini memungkinkan para desainer untuk memiliki pemahaman awal tentang apakah detail konstruksi kemungkinan akan mencapai persyaratan kinerja respons termal sebelum melanjutkan dengan pendekatan pemodelan yang lebih detail.

16.2 PEMBELAJARAN MESIN DALAM SFE

Meskipun sudah umum digunakan di berbagai bidang teknik lainnya, penerapan pembelajaran mesin dan ilmu data dalam rekayasa kebakaran struktural masih tergolong baru. Salah satu penelitian mengadopsi kecerdasan buatan dan pembelajaran mesin untuk mengusulkan model material termal dan mekanis baru yang bergantung pada suhu untuk baja struktural, serta memvalidasinya melalui beberapa studi kasus. Penelitian selanjutnya memperluas pendekatan tersebut dengan mempertimbangkan struktur kayu dan mengusulkan model material berbasis suhu untuk memprediksi kinerja termal dan mekanis anggota kayu struktural.

Pendekatan lain menggunakan jaringan saraf tiruan untuk menentukan tahanan geser sisa balok beton bertulang setelah kebakaran melalui analisis elemen hingga di perangkat lunak simulasi. Data yang dikumpulkan berjumlah ratusan entri dan digunakan untuk pelatihan serta pengujian model. Penelitian lain juga memanfaatkan jaringan saraf fuzzy untuk memprediksi ketahanan api kolom beton bertulang dengan beban eksentrik, menggunakan model adaptif yang tersedia dalam perangkat analisis numerik.

Selain itu, pendekatan pembelajaran mendalam berbasis jaringan saraf konvolusional (CNN) juga dikembangkan untuk mendeteksi pola retak pada balok beton yang mengalami kebakaran. Metode ini menganalisis data visual dari permukaan balok yang rusak dengan bantuan kamera digital. Model jaringan saraf lainnya digunakan untuk memprediksi kemungkinan terjadinya spalling eksplosif pada beton bertulang serat polipropilena saat kebakaran. Dua model disajikan, yaitu berbasis campuran beton dan berbasis kekuatan beton, dengan tingkat akurasi prediksi yang sangat tinggi.

Teknik jaringan saraf juga telah diterapkan untuk memprediksi respons rotasi momen sambungan semi-kaku dalam kondisi kebakaran, dengan pelatihan dan pengujian yang dilakukan menggunakan data deret waktu dari percobaan kebakaran nyata. Pendekatan serupa kemudian digunakan untuk memprediksi respons rotasi momen pada sambungan las. Di sisi lain, kerangka kerja akuisisi data berbasis metode Monte Carlo dan Random Sampling diusulkan untuk menghasilkan dataset mengenai pola kegagalan pada bangunan rangka baja.

Dataset tersebut kemudian digunakan untuk melatih pengklasifikasi jaringan saraf tiruan (ANN) untuk menyelidiki potensi kegagalan dengan cepat untuk pengaturan desain yang berbeda. Sebagaimana terlihat dari contoh-contoh di atas, fokus penelitian saat ini terutama

didasarkan pada pengembangan model-model pembangunan mesin menggunakan data eksperimen yang diperoleh di laboratorium. Kerangka kerja yang diusulkan dalam bab ini didasarkan pada model numerik dan dirancang khusus untuk digunakan oleh praktisi teknik kebakaran struktural.

16.3 KERANGKA KERJA PENGEMBANGAN MODEL PENGGANTI

Inspirasi

Penggunaan model pengganti berdasarkan data pra-komputasi bukanlah pendekatan baru dalam rekayasa. Sebelum pengembangan metode (FE) dan kemajuan komputasi sejak akhir 1960-an, para insinyur menggunakan berbagai bagan ukuran, yang bertindak sebagai pengganti, merepresentasikan solusi perkiraan persamaan diferensial parsial perpindahan panas untuk berbagai geometri dasar seperti pelat, bola, dan silinder. Penilaian rekayasa digunakan untuk mengaproksimasi bentuk dan kondisi batas termal dari detail yang dipelajari dengan kombinasi solusi representatif dari bagan ukuran. Namun, dengan pengembangan metode FE, pendekatan ini mulai kurang populer, karena FEA memungkinkan prediksi respons termal geometri yang dianalisis lebih akurat tanpa perlu aproksimasi ke bentuk yang lebih sederhana. Sebagaimana dibahas di atas, FEA merupakan pendekatan komputasi yang intensif, dan seringkali tidak praktis untuk menganalisis semua kombinasi geometri potensial.

Perangkat berbasis ML yang dibangun berdasarkan data eksperimen dan numerik dapat meningkatkan efisiensi komputasi dan pengambilan keputusan dini secara signifikan, sebagaimana dibahas oleh Salehi dan Burgueno dalam tinjauan mereka tentang tren ML yang sedang berkembang dalam rekayasa struktur. Bab ini menyajikan "versi modern yang setara" dari bagan ukuran tradisional dengan melatih model ML pada data perpindahan panas yang telah dihitung sebelumnya. Ini merupakan aplikasi baru dari pendekatan berbasis ML untuk permasalahan rekayasa kebakaran struktur.

Kesesuaian

Metodologi yang diusulkan sesuai untuk kasus-kasus di mana ruang parametrik yang diselidiki telah dieksplorasi secara menyeluruh sejak awal dengan simulasi terverifikasi yang memadai atau terdapat sumber data relevan lainnya (misalnya, bukti empiris dari eksperimen). Desain kueri juga harus konsisten dan memadai untuk memanfaatkan kecepatan penilaian yang lebih tinggi. Panduan untuk menilai jumlah data yang dibutuhkan dibahas dalam setiap studi kasus di bab ini.

Namun, penting bahwa parameter dari kumpulan data yang disediakan mencakup rentang nilai yang cukup besar, sehingga kueri di masa mendatang berada dalam rentang data yang telah dilatih oleh algoritma ML. Sebagaimana diperkirakan, sebagian besar algoritma ML akan berkinerja buruk ketika diminta untuk melakukan ekstrapolasi di luar batas data yang telah dilatih.

Perlu dicatat bahwa upaya signifikan didedikasikan untuk memperoleh kumpulan data awal, yang seringkali memerlukan simulasi terpisah untuk setiap titik data. Namun, pengalaman dari penerapan praktis sistem untuk desain telah menunjukkan bahwa setelah

sistem ML dibangun, penghematan waktu yang ditawarkan oleh penilaian cepat lebih besar daripada upaya awal untuk mengembangkan sistem tersebut.

Komponen Sistem

Model pengganti ML yang diusulkan terdiri dari tiga komponen:

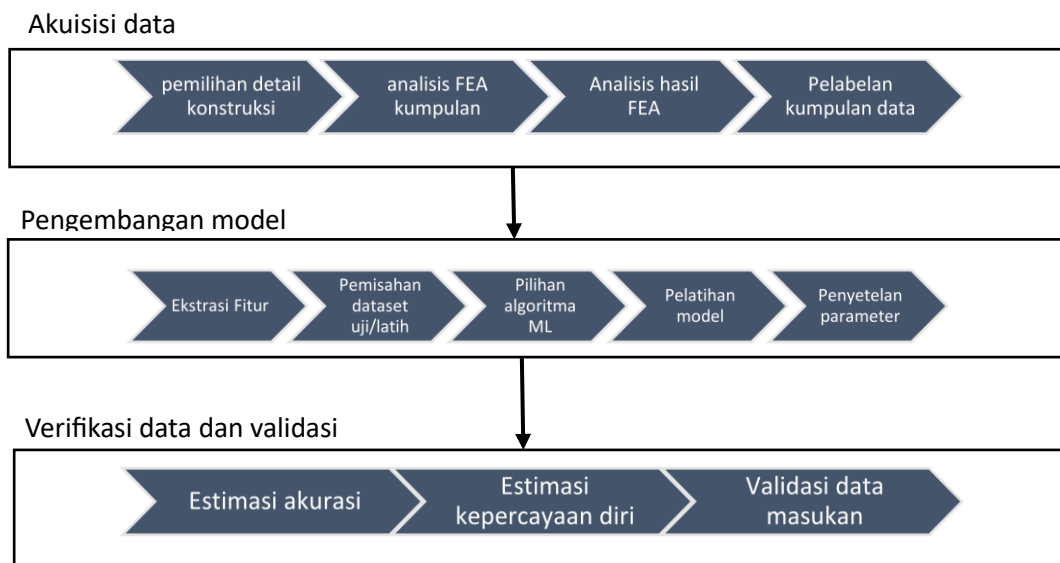
- (1) Validator data yang menilai apakah data masukan mewakili data yang telah dilatihkan pada model.
- (2) Algoritma ML yang membuat prediksi dengan akurasi yang memadai.
- (3) Estimator keyakinan prediksi.

Meskipun komponen kedua bertanggung jawab untuk memberikan hasil, fungsi simultan dari komponen pertama dan ketiga memastikan bahwa sistem digunakan dengan tepat, dan prediksi tersebut valid. Hal ini penting untuk setiap kalkulasi teknik yang membutuhkan demonstrasi bahwa keluaran mencapai tingkat keandalan tertentu.

Perlu dicatat juga bahwa manfaat maksimal dari sistem semacam itu diperoleh ketika terintegrasi dengan baik dalam alur kerja yang lebih besar. Seringkali integrasi yang efisien memberikan manfaat yang lebih besar daripada pilihan algoritma ML asalkan akurasi yang memadai tercapai karena proses seperti pengelolaan data masukan, pemrosesan, dan pelaporan hasil menjadi memakan waktu jika dilakukan dalam skala besar. Ketika diterapkan pada konstruksi, merinci integrasi yang tepat ke platform manajemen data umum seperti BIM (*Building Information Model*) merupakan solusi potensial.

Proses Pengembangan

Membangun model pengganti berbasis ML merupakan proses multistap yang secara garis besar dapat dibagi menjadi beberapa tahap berikut: akuisisi data, pengembangan model, pengembangan komponen untuk validasi, dan verifikasi. Setiap tahap ini dapat mencakup semua atau sebagian proses seperti yang ditunjukkan pada Gambar 16.1. Pencapaian praktis setiap tahap dibahas melalui dua studi kasus di Bagian 4 bab ini. Kedua studi kasus membahas permasalahan perpindahan panas yang umum dalam rekayasa kebakaran struktural. Kompleksitasnya bervariasi dan menunjukkan berbagai subtahap. Algoritme untuk kedua studi kasus yang dijelaskan dalam bab ini diimplementasikan dengan Python 3.6 dan pustaka *sci-kit—learn*.



Gambar 16.1: Proses pengembangan untuk model pengganti ML.

16.4 CONTOH STUDI KASUS

Dua studi kasus yang mengilustrasikan kerangka kerja ML yang dibahas di Bagian 2 disajikan. Studi kasus pertama membahas penggunaan ML untuk prediksi peringkat klasifikasi kebakaran untuk detail konstruksi balok komposit. Studi kasus kedua menyajikan metodologi ML untuk prediksi peringkat klasifikasi kebakaran untuk detail konstruksi lantai dangkal komposit.

Proteksi Balok Komposit


Balok komposit didefinisikan sebagai baja canai panas berpenampang I atau H yang dihubungkan melalui konektor geser ke pelat lantai beton pracetak atau komposit di mana penampang baja dan pelat lantai dirancang untuk bekerja bersama/komposit. Jika terjadi kebakaran, baja berpenampang I atau H dapat terpapar api dari bawah. Proteksi kebakaran biasanya diterapkan pada balok untuk membatasi kenaikan suhu baja sehingga memungkinkannya mempertahankan stabilitas strukturalnya. Metode umum untuk memberikan proteksi kebakaran ini adalah dengan membungkus bagian balok yang terbuka dengan bahan yang tidak mudah terbakar seperti papan atau wol mineral.

Verifikasi stabilitas dapat ditunjukkan dengan membatasi kenaikan suhu balok baja di bawah suhu kritis. Suhu kritis ini bergantung pada jenis elemen struktural (misalnya, balok atau kolom) dan rasio beban yang diberikan terhadap kapasitas struktural elemen tersebut. Menurut Buku Kuning Asosiasi Spesialis Proteksi Kebakaran, suhu batas untuk konstruksi balok komposit biasanya ditetapkan sebesar 550°C jika tidak ada informasi pembebanan dan detail penampang yang spesifik.

Peringkat ketahanan api balok baja yang merupakan bagian dari konstruksi komposit didefinisikan sebagai waktu di mana balok baja melampaui suhu batas 550°C ketika dipanaskan hingga kurva suhu waktu api standar ISO 834 yang dibulatkan ke 30 menit terdekat. Dalam industri, BS EN 1993-1-2 menyediakan model perpindahan panas kapasitas terdistribusi yang umum digunakan untuk menghitung kenaikan suhu balok baja yang dilindungi dan

selanjutnya mengevaluasi peringkat apinya. Model ini mengasumsikan perpindahan panas satu dimensi melalui proteksi kebakaran yang membungkus balok menggunakan perhitungan langkah waktu iteratif.

Gambar 16.2 menunjukkan contoh kenaikan suhu untuk balok UKB 305x105x25 yang dilindungi. Suhu batas 620°C terlampaui pada menit ke-60, sehingga peringkat ketahanan apinya adalah 60 menit. Secara tradisional, perhitungan BS EN 1993-1-2 perlu diulang untuk setiap perubahan ukuran penampang atau ketebalan bahan isolasi. Untuk menghindari hal ini dan memungkinkan penilaian yang lebih cepat, diusulkan untuk menggunakan model ML yang dilatih pada kumpulan data yang terdiri dari hasil perhitungan awal.



Gambar 16.2: Perkembangan suhu pada balok terlindungi yang terpapar api standar.

Akuisisi Data dan Pemilihan Fitur

Tingkat ketahanan api balok baja bergantung pada dua variabel utama saat menggunakan model perhitungan Eurocode 3. Pertama, rasio luas permukaan balok yang dipanaskan (A) terhadap volume (V) balok. Rasio ini dikenal sebagai "Faktor Penampang". Elemen struktural dengan faktor penampang rendah akan membutuhkan waktu lebih lama untuk memanaskan dibandingkan dengan elemen dengan faktor penampang tinggi. Faktor-faktor ini bergantung pada geometri penampang. Nilai untuk ukuran penampang standar seperti yang dipilih untuk studi kasus ini tersedia dalam lembar data teknis yang tersedia untuk umum.

Variabel utama lainnya adalah jenis dan ketebalan proteksi kebakaran yang diterapkan. Dalam contoh ini, insulasi wol mineral digunakan sebagai metode proteksi kebakaran. Berdasarkan tinjauan lembar data teknis pemasok, ditemukan bahwa ketebalannya biasanya berada di kisaran 25–55 mm. Perhitungan BS EN 1993-1-2 dilakukan untuk menentukan kenaikan suhu pada 26 penampang baja dengan perlindungan wol mineral 25–55 mm.

Hasilnya adalah total 156 detail unik. Penampang dipilih agar mewakili seluruh rentang ukuran katalog penampang baja standar Inggris. Rentang ukuran utama dirangkum dalam Tabel 16.1.

Tabel 16.1: Ringkasan dataset balok komposit.


Parameter	Rentang
<i>Tinggi</i>	<i>127 mm – 1026 mm</i>
<i>Lebar</i>	<i>76 mm – 424 mm</i>
<i>Tebal Flens</i>	<i>7.6 mm – 77 mm</i>
<i>Tebal Badan</i>	<i>4 mm – 47.6 mm</i>
<i>Faktor Penampang</i>	<i>31 m⁻¹ – 325 m⁻¹</i>
<i>Tebal Isolasi</i>	<i>25 mm – 55 mm</i>

Setiap detail yang dianalisis kemudian diklasifikasikan berdasarkan kriteria insulasi yang dibahas pada Bagian 4.1.1. Distribusi klasifikasi dirangkum dalam Tabel 16.2.

Tabel 16.2: Distribusi klasifikasi.

Kelas (Durasi)	Jumlah	Persentase
<i>30 menit</i>	8	5%
<i>60 menit</i>	25	16%
<i>90 menit</i>	33	21%
<i>120 menit</i>	44	28%
<i>180 menit</i>	22	14%
<i>240 menit</i>	24	15%

Diagram sebar antara faktor penampang dan ketebalan proteksi yang diberikan disajikan pada Gambar 16.3. Warna titik data menunjukkan klasifikasi peringkat api sesuai dengan metodologi BS EN 1993-1-2. Seperti yang terlihat pada Gambar 16.3, semua titik data dapat dengan mudah dipisahkan secara spasial berdasarkan kelasnya. Hal ini digambarkan oleh garis putus-putus merah yang menandakan batas keputusan potensial. Kemampuan untuk memisahkan kelas data secara visual menunjukkan kemungkinan kinerja yang baik dari pengklasifikasi ML yang telah dipasang.



Gambar 16.3: Batas keputusan potensial ditunjukkan dengan garis putus-putus merah.

Pemilihan Model


Model ML yang dipasang pada data yang diperoleh didasarkan pada algoritma *Support Vector Machine* (SVM), sebuah algoritma klasifikasi pembelajaran terbimbing yang bertujuan untuk menemukan hiperbidang yang memisahkan dua atau lebih kelas titik data. Algoritma ini beriterasi untuk menemukan hiperbidang yang paling optimal, yaitu bidang yang memiliki lebar margin maksimum antara titik-titik data dari kelas yang berbeda, yang dikenal sebagai vektor pendukung (Gambar 16.4).

Pertimbangan berikut diberikan untuk pemilihan SVM dibandingkan algoritma klasifikasi pembelajaran terbimbing lainnya:

- SVM adalah algoritma geometrik dan tidak memerlukan sejumlah besar titik data untuk mencapai akurasi yang dapat diterima karena batas keputusan hanya dipengaruhi oleh titik-titik data yang paling dekat dengan batas keputusan, yaitu vektor pendukung. Nantinya akan ditunjukkan bahwa properti ini dapat digunakan untuk secara signifikan mengurangi data yang diperlukan untuk melatih model.
- Transformasi hiperbidang SVM menjadi garis untuk dataset 2D yang menawarkan tingkat visualisasi dan interpretabilitas hasil yang tinggi.
- SVM, sebagai pengklasifikasi margin maksimum, berkinerja baik dengan data yang dapat dipisahkan secara linear. Dataset yang diteliti diharapkan dapat dipisahkan secara linear (pada beberapa kombinasi fitur) karena dihasilkan oleh proses deterministik (simulasi FEA) pada larik terkontrol dari masukan yang didefinisikan secara tepat. Oleh karena itu, derau dalam dataset keluaran diharapkan dapat diabaikan.
- SVM dapat ditingkatkan dengan fungsi kernel untuk menemukan batas keputusan nonlinier. Fungsi kernel adalah fungsi transformasi yang diterapkan pada fitur data yang

ada sehingga dataset yang ditransformasi dapat dipisahkan oleh hiperbidang. Proyeksi hiperbidang yang telah disesuaikan dalam ruang data asli membentuk batas keputusan nonlinier.

- SVM telah terbukti bekerja dengan baik dengan permasalahan rekayasa struktural terkait data sebagaimana dibahas oleh Cevic dkk.



Gambar 16.4: Demonstrasi SVM mengenai prinsip operasi.

Pengaturan Model

Seperti yang terlihat dari analisis data eksploratori yang dibahas pada 4.1.2, data tampak dapat dipisahkan secara linear ketika direpresentasikan sebagai kombinasi faktor penampang dan fitur ketebalan wol mineral yang diterapkan. Hal ini menunjukkan bahwa pelatihan algoritma SVM pada kedua fitur ini berpotensi mencapai kinerja yang baik. Karena kedua fitur tersebut memiliki rentang orde magnitudo yang berbeda (isolasi: 10⁻², faktor penampang: 10²), normalisasi diimplementasikan untuk meningkatkan kinerja. Hal ini karena pengklasifikasi geometri sensitif terhadap jarak antara titik data yang berbeda dalam ruang parametrik. Oleh karena itu, ketika fitur diukur pada skala yang berbeda, salah satu fitur dapat menjadi dominan secara tidak semestinya atas yang lain.


Fungsi kernel basis radial (RBF) juga dipertimbangkan untuk mengakomodasi batasan keputusan nonlinier yang terlihat pada Gambar 16.2. RBF adalah fungsi transformasi yang mentransformasi fitur data yang ada ke ruang berdimensi lebih tinggi di mana hiperbidang optimal dapat dipasang. Secara spesifik, kernel RBF adalah fungsi transformasi yang menghasilkan fitur baru dengan mengukur kedekatan setiap titik data ke suatu pusat tetap dalam ruang data. Biasanya, pusat dipilih sebagai titik data itu sendiri. Kinerja model SVM juga bergantung pada pilihan hiperparameter yang spesifik. Hiperparameter ini tidak bergantung pada data yang disediakan dan didefinisikan sebelum tahap pembelajaran. Hiperparameter optimal biasanya dipilih melalui pencarian parametrik yang ekstensif. Hiperparameter yang dipertimbangkan dalam studi kasus ini disajikan pada Tabel 16.3.

Tabel 16.3: Deskripsi hiperparameter yang dipertimbangkan.


Hyperparameter	Deskripsi	Rentang Uji
C-value	C-value adalah ukuran tingkat toleransi algoritma terhadap kesalahan klasifikasi pada titik yang berada dekat dengan batas keputusan. Nilai C yang rendah berarti toleransi tinggi (soft margin), yaitu algoritma lebih longgar terhadap kesalahan klasifikasi. Sebaliknya, nilai C yang tinggi (hard margin) memberikan penalti besar terhadap kesalahan klasifikasi. Penalti yang terlalu ketat dapat menyebabkan model overfit, yaitu sangat sesuai dengan data latih tetapi gagal memberikan hasil akurat pada data uji.	$10^{-4} - 10^{15}$
gamma	Gamma mengontrol kekuatan fungsi kernel RBF dalam memengaruhi letak batas keputusan seperti telah dijelaskan di atas.	$10^{-3} - 10^6$

Estimasi Kinerja

Untuk setiap set hiperparameter, akurasi rata-rata model diestimasi mengikuti prosedur validasi silang 5 kali lipat. Akurasi diukur sebagai fraksi klasifikasi yang benar pada set validasi silang. Hasil pencarian parametrik disajikan pada peta panas pada Gambar 16.4. Model kernel SVM RBF terbaik dari kohort yang diteliti mencapai skor akurasi maksimum 0,96 (nilai-C = 10000000, gamma = 0,001). Model divisualisasikan secara detail pada Gambar 16.5. Seperti yang terlihat pada Gambar 16.6, hasil kecocokan yang dicapai cukup baik untuk tujuan yang dinyatakan. Akurasi estimasi sebesar 96% pada data yang tidak terlihat cukup mendekati kinerja tingkat manusia sebesar 100%. Hal ini dapat ditingkatkan lebih lanjut dengan menambahkan titik data tambahan di sekitar batas. Ketergantungan juga ditingkatkan oleh fakta bahwa hasil dapat dengan mudah divisualisasikan dalam cara yang dapat ditafsirkan karena sifat dataset yang dua dimensi.



Gambar 16.5: SVM dengan pencarian hiperparametrik kernel RBF.




Gambar 16.6: Visualisasi model SVM yang optimal.

Proteksi Sistem Lantai Ramping

Pendahuluan Masalah

Sistem lantai ramping adalah sistem komposit lantai di mana bagian baja tertanam sebagian di dalam pelat beton (Gambar 16.7) untuk mengurangi kedalaman total konstruksi lantai sehingga memungkinkan pemanfaatan ruang yang lebih efektif. Namun, penanaman baja memfasilitasi perpindahan panas yang efisien melalui pelat, yang dapat memengaruhi kinerja konstruksi tahan api. Solusi potensial untuk masalah ini adalah dengan membungkus seluruh bagian baja yang terbuka dengan sistem proteksi kebakaran yang sesuai. Namun, hal ini seringkali sulit dicapai untuk sistem lantai dangkal yang mungkin memiliki rangka baja yang terbuka di permukaan atasnya karena keterbatasan ruang di rongga lantai yang terkadang menyulitkan perlindungan flensa atas.




Gambar 16.7: Diagram sistem lantai ramping.

Analisis elemen hingga perpindahan panas sering diterapkan untuk menentukan peringkat ketahanan api detail jika flensa atas dibiarkan tidak terlindungi. Analisis ini memantau perambatan panas melalui detail ketika berada dalam kondisi batas berikut:

- Paparan permukaan atas detail terhadap kurva waktu suhu api standar ISO 834 melalui kondisi batas konvektif dan radiatif sesuai dengan BS 1993-1-2.
- Permukaan bawah detail terpapar suhu lingkungan yang konstan.
- Sifat material beton dan baja yang bergantung pada suhu diasumsikan sesuai dengan rekomendasi BS 1993-1-2 dan BS EN 1992-1-2.

Contoh distribusi termal detail lantai ramping setelah paparan api standar selama 120 menit ditunjukkan pada Gambar 16.8.



Gambar 16.8: Respons termal detail lantai ramping. Satuan dalam K [16].

Peringkat ketahanan api ditentukan sebagai waktu paparan di mana salah satu dari kriteria pembatas berikut dilanggar sesuai dengan Klausul 11.3 BS EN 1363-1:2012:

- ✓ Suhu rata-rata pada sisi yang tidak terpapar melebihi 140° di atas suhu sekitar (20°C).
- ✓ Suhu maksimum pada sisi yang tidak terpapar melebihi 180°C di atas suhu sekitar (20°C).

Untuk tujuan kualifikasi ketahanan api, waktu tersebut kemudian dibulatkan ke salah satu kategori peringkat ketahanan api standar: 60 menit, 90 menit, 120 menit, dan 180 menit.

Secara tradisional, analisis semacam itu idealnya dilakukan untuk setiap geometri yang berbeda. Keterbatasan waktu proyek seringkali hanya memungkinkan sejumlah kecil geometri untuk diperiksa. Pertimbangan teknis harus dilakukan dalam memilih detail mana yang harus menjalani analisis lebih lanjut. Pendekatan ini subjektif dan dapat menyebabkan kesalahan. Untuk mengurangi risiko ini, diusulkan untuk menggunakan algoritma ML yang dilatih berdasarkan hasil simulasi sebelumnya untuk memprediksi kinerja kebakaran yang diharapkan dari detail tersebut tanpa memerlukan simulasi eksplisit.

Akuisisi Data


Kumpulan data ini terdiri dari hasil perhitungan FEA dari model yang mendekati konstruksi lantai ramping. Paket perangkat lunak FEA serbaguna LS-DYNA v6.1.1 digunakan untuk setiap perhitungan. Dua puluh enam ukuran penampang dipilih untuk mencakup seluruh rentang ukuran katalog UKB/UKC. Untuk pemodelan, geometri penampang 'I' simetris ganda telah disederhanakan menjadi empat parameter: tinggi penampang, lebar penampang, tebal flens, dan tebal badan.

Setiap penampang tertanam dalam pelat beton dengan ketebalan berkisar antara 100 mm–250 mm. Jumlah total kasus yang dianalisis adalah 182. Parameter kumpulan data, termasuk rentang nilai (nilai minimum dan maksimum), dirangkum dalam Tabel 16.4. Rentang indikatif geometri model yang dihasilkan divisualisasikan dalam Gambar 16.9.

Tabel 16.4: Ringkasan fitur kumpulan data.

Fitur	Deskripsi	Rentang Nilai
Tebal beton	concT	100–250 @ kenaikan 25 mm
Tinggi penampang	sech	127,5–1026 mm
Lebar penampang	secW	76–424 mm
Tebal flange	secTw	7,4–77,5 mm
Tebal web	secTf	4–47,8 mm

Perlu dicatat bahwa beberapa detail yang diteliti mungkin tidak umum digunakan dalam praktik konstruksi. Namun, detail tersebut dimasukkan sebagai bagian dari studi ini untuk membantu kelengkapan dataset dan memastikan bahwa detail yang digunakan dalam konstruksi berada dalam batasan dataset yang diteliti. Penampang asimetris tidak disertakan dalam studi ini, tetapi dapat dipertimbangkan dengan cara yang sama menggunakan pendekatan berbasis ML yang disajikan.



Gambar 16.9: Fraksi representatif dari berbagai geometri (20 dari 182 ditampilkan).

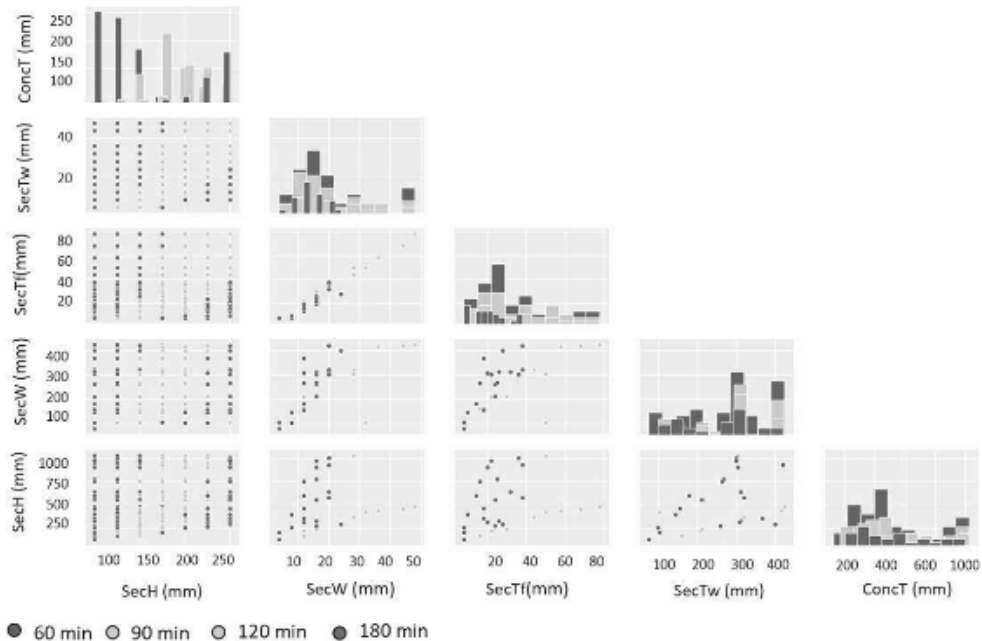
Setiap detail yang dianalisis diklasifikasikan menurut kriteria insulasi yang dibahas pada Bagian 5.3. Distribusi klasifikasi dirangkum dalam Tabel 16.5.

Tabel 16.5: Distribusi klasifikasi.


Kelas (Durasi)	Jumlah	Persentase
60 menit	75	41%
90 menit	48	26%
120 menit	32	18%
180 menit	27	15%

Pemilihan Fitur

Dataset yang diperoleh awalnya diperiksa secara visual dengan memplot 10 plot sebar di antara masing-masing dari 5 parameter masukan utama yang disajikan pada Tabel 16.4. Klasifikasi setiap titik data ditampilkan dengan warna yang berbeda. Plot sebar disajikan pada Gambar 16.10. Tujuan latihan ini adalah dengan memeriksa secara visual posisi berbagai kelas pada berbagai plot sebar untuk menyimpulkan parameter mana yang paling mungkin mengatur masalah klasifikasi. Plot sebar di antara variabel-variabel di mana kelas-kelas tampak terpisah dengan baik menunjukkan bahwa klasifikasi kemungkinan besar bergantung secara signifikan pada parameter-parameter ini. Sebaliknya, plot di mana pemisahan spasial antar kategori tidak terlihat menunjukkan bahwa kombinasi variabel bukanlah indikator klasifikasi yang baik.



Gambar 16.10: Plot sebar antara fitur himpunan data (Panev et al., 2021).



Gambar 16.11: Diagram sebar antara ketebalan web dan ketebalan pelat beton menunjukkan tingkat keterpisahan yang baik.

Pemeriksaan lebih dekat menunjukkan bahwa ketebalan pelat beton dan ketebalan badan penampang tampaknya menjadi penentu yang baik untuk kelas insulasi tahan api. Gambar 16.11 menunjukkan bahwa semua titik data dapat dengan mudah dipisahkan secara spasial menurut kelasnya. Hal ini digambarkan oleh garis putus-putus merah yang menandakan batas keputusan potensial. Simpulan bahwa ketebalan web dan ketebalan beton merupakan parameter utama yang mengatur masalah klasifikasi ini juga didukung oleh dua prinsip berikut dari teori konduksi panas yang menunjukkan hubungan kausal berikut:

- Ketebalan pelat beton menentukan jarak konduksi panas yang dibutuhkan untuk mencapai sisi belakang detail. Seperti terlihat pada Gambar 16.9, pelat yang lebih tebal membutuhkan waktu lebih lama agar konduksi terjadi, sehingga menghasilkan peringkat klasifikasi insulasi yang lebih tinggi.
- Untuk analisis 2D yang dipertimbangkan, luas material baja yang sangat konduktif (relatif terhadap beton di sekitarnya) sama dengan ketebalan web penampang. Konduksi yang lebih efisien difasilitasi oleh luas permukaan konduktif yang lebih tinggi. Hal ini terlihat pada Gambar 16.9 karena peringkat klasifikasi menurun seiring bertambahnya ketebalan web.

Dengan mempertimbangkan kedua prinsip dasar perilaku termal ini dan hasil analisis data eksplorasi, langkah selanjutnya adalah melakukan pelatihan lebih lanjut terhadap model

pembelajaran mesin terawasi dengan mengadopsi ketebalan beton dan ketebalan badan sebagai fitur input. Hal ini juga didukung oleh pertimbangan tambahan berikut:

- Menyertakan fitur-fitur yang kurang signifikan terhadap permasalahan yang diteliti dapat menimbulkan derau yang tidak perlu, yang akan menurunkan akurasi model.
- Kebutuhan untuk memasukkan fitur tambahan akan terlihat jelas dalam proses pengujian model.
- Merupakan praktik yang baik untuk menggunakan fitur masukan sesedikit mungkin guna meningkatkan interpretabilitas model. Lebih lanjut, untuk kasus khusus dengan dua fitur, semua hasil dapat divisualisasikan dengan plot kontur yang secara signifikan meningkatkan keterbacaan dan pemahaman model oleh para desainer yang ingin menggunakannya sebagai alat bantu.

Pelatihan dan Performa Model

Seperti yang terlihat dari analisis data eksploratori yang dibahas pada 4.2.3, data tampak dapat dipisahkan secara linear ketika direpresentasikan sebagai kombinasi fitur ketebalan pelat beton dan ketebalan badan penampang. Dengan pertimbangan serupa seperti pada studi kasus balok komposit, algoritma SVM diadopsi untuk klasifikasi terbimbing. Penyertaan RBF juga dipertimbangkan untuk mengakomodasi batasan keputusan yang berpotensi non-linear.

Hiperparameter model SVM disetel menggunakan pencarian grid pada rentang nilai yang ditunjukkan pada Tabel 16.6. Untuk setiap set hiperparameter, akurasi rata-rata model diestimasi dengan mengikuti prosedur validasi silang 5 kali lipat. Hasil pencarian parametrik disajikan pada peta panas pada Gambar 16.12. Visualisasi kecocokan untuk enam model berbeda dengan berbagai kombinasi hiperparameter ditunjukkan pada Gambar 16.13. Grafik merepresentasikan data yang digunakan untuk pelatihan sebagai titik dan prediksi model sebagai warna latar belakang. Interaksi antara efek berbagai hiperparameter dapat diamati dengan mudah.

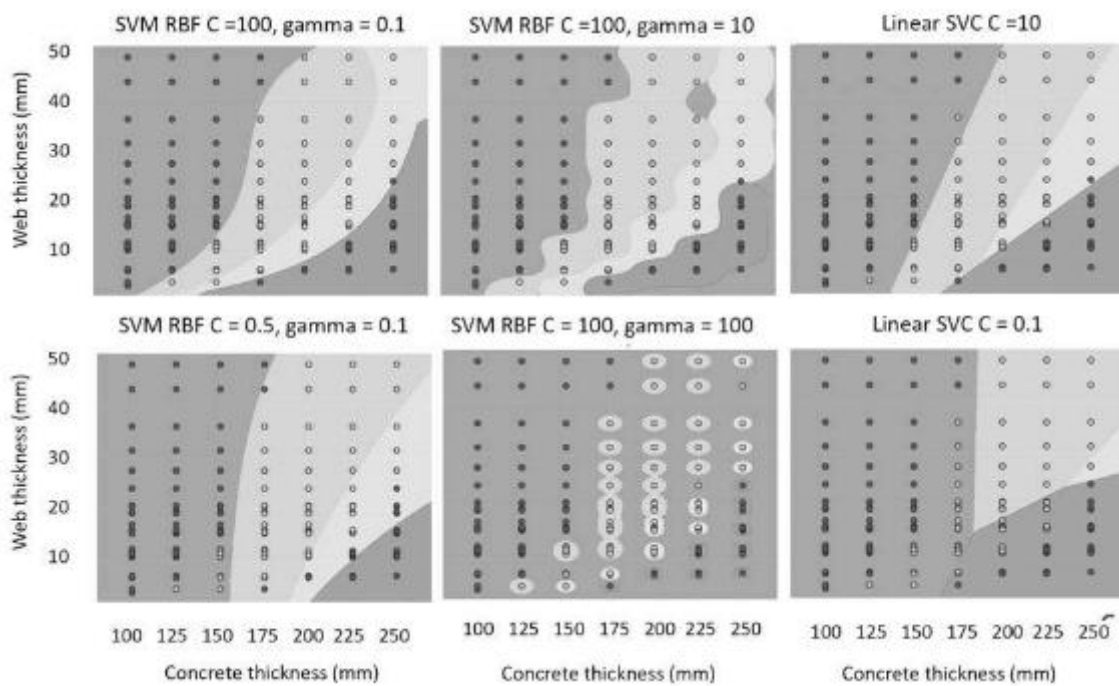
Model kernel SVM RBF terbaik dari kohort yang diteliti mencapai skor akurasi maksimum 0,96 (nilai-C = 100, gamma = 0,1). Model divisualisasikan secara detail pada Gambar 16.14, yang menunjukkan bahwa kecocokan yang dicapai cukup baik untuk tujuan yang dinyatakan. Akurasi estimasi 96% pada data yang tidak terlihat cukup mendekati kinerja tingkat manusia sebesar 100%. Hal ini dapat ditingkatkan lebih lanjut dengan memasukkan titik data tambahan di sekitar batas. Keandalan juga ditingkatkan oleh fakta bahwa hasil dapat dengan mudah divisualisasikan dengan cara yang dapat diinterpretasikan karena sifat dataset 2D.

Tabel 16.6: Rentang hiperparameter untuk studi kasus slim-floor.


Hiperparameter	Rentang Uji
Nilai-C	$10^{-4} - 10^5$
gamma	$10^{-3} - 10^6$

C \ Gamma	0.0001	0.001	0.01	0.1	1.0	10.0	100.0	1000.0	10000.0
0.001	0.42	0.42	0.42	0.42	0.42	0.42	0.42	0.42	0.42
0.01	0.42	0.42	0.42	0.67	0.42	0.42	0.42	0.42	0.42
0.1	0.42	0.42	0.51	0.89	0.88	0.88	0.79	0.66	0.49
1.0	0.42	0.51	0.90	0.92	0.94	0.88	0.81	0.69	0.52
10.0	0.51	0.90	0.89	0.96	0.95	0.88	0.81	0.69	0.52
100.0	0.90	0.86	0.94	0.95	0.95	0.88	0.81	0.69	0.52
1000.0	0.85	0.89	0.94	0.95	0.95	0.88	0.81	0.69	0.52
10000.0	0.88	0.94	0.93	0.95	0.94	0.88	0.81	0.69	0.52
100000.0	0.91	0.94	0.93	0.93	0.94	0.88	0.81	0.69	0.52

Gambar 16.12: SVM dengan pencarian parametrik kernel RBF.



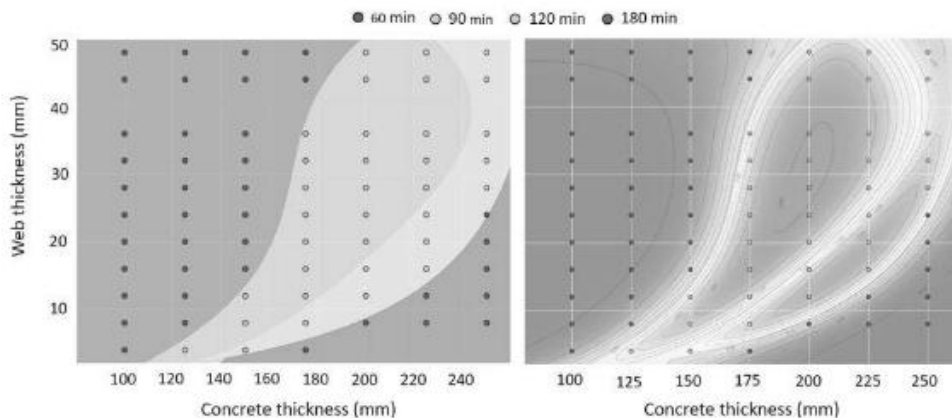
Gambar 16.13: Visualisasi model untuk berbagai hiperparameter.



Gambar 16.14: Model SVM optimal.

Estimasi Keyakinan

Untuk meningkatkan keandalan model ML, diputuskan untuk menyertakan estimasi keandalan di samping prediksi peringkat klasifikasi. Seperti yang terlihat pada Gambar 16.4, SVM dikembangkan untuk menilai jarak Euclidian ("garis lurus") antara prediksi dan batas keputusan yang telah disesuaikan (bidang hiper). Namun, jarak ini bersifat spesifik model sehingga menyulitkan pengguna untuk mengukur besarnya tanpa memiliki pengetahuan mendalam tentang isi dataset yang digunakan. Untuk mengatasi ketergantungan model ini, teknik transformasi penskalaan Platt (Platt John, 2000) digunakan untuk memetakan jarak antara titik data dan batas keputusan antara nilai yang berkisar dari 0,5 (dicapai pada batas) dan 1 (dicapai lebih jauh dari batas).



Gambar 16.15: Perbandingan antara model SVM dengan (kiri) dan tanpa (kanan) penskalaan Platt.

Pada prinsip dasarnya, penskalaan Platt bekerja dengan menyesuaikan regresi logistik dengan skor yang dihasilkan oleh SVM. Perlu dicatat bahwa teknik ini diadopsi hanya untuk memberikan "ukuran yang konsisten" dari kekuatan relatif prediksi berdasarkan jarak dari batas keputusan dalam dataset yang sama. Implementasi ini tidak dimaksudkan untuk membandingkan hasil prediksi antar model ML yang berbeda atau untuk menyimpulkan distribusi probabilitas empiris. Gambar 16.15 memvisualisasikan model SVM RBF dengan performa terbaik (kiri) yang disempurnakan dengan teknik penskalaan Platt (kanan). Intensitas warna latar belakang pada gambar di sebelah kanan merepresentasikan peringkat skala, yaitu seberapa dekat prediksi dengan batas keputusan. Garis kontur merepresentasikan nilai numerik peringkat, yaitu nilai antara 0,5–1.


Perlu dicatat bahwa untuk dataset 2D, penggunaan teknik penskalaan Platt untuk menginformasikan keandalan prediksi dapat menjadi usang untuk pekerjaan yang disajikan dalam makalah ini karena pengguna dapat memeriksa secara visual seberapa dekat prediksi dengan batas keputusan. Namun, visualisasi yang akurat sulit atau bahkan tidak mungkin dilakukan dalam permasalahan yang lebih kompleks yang melibatkan lebih dari tiga fitur. Skala Platt, di sisi lain dapat dengan mudah diterapkan untuk kumpulan data berdimensi lebih tinggi.

16.5 KETERBATASAN PENDEKATAN PEMBELAJARAN MESIN

Keterbatasan yang dibahas di bagian ini diamati dalam kedua studi kasus dan kesimpulan yang ditarik untuk memitigasinya dipertimbangkan. Contoh relevan dari setiap studi disediakan jika sesuai.

Validasi Data Input


Karena model pembelajaran mesin berbasis geometri mengambil informasi dari posisi geometris relatif antar titik data, model tersebut berkinerja buruk di wilayah yang jauh dari kumpulan data. Gambar 16.16 menunjukkan kemampuan ekstrapolasi yang buruk untuk model SVM yang dilatih pada kumpulan data slim-floor. Hal ini menggambarkan bahwa setiap data input ke dalam sistem prediktif harus diverifikasi terlebih dahulu agar representatif terhadap kumpulan data tempat model prediktif telah dilatih. Setiap outlier akan ditandai sebagai anomali dan notifikasi akan diberikan kepada pengguna.




Gambar 16.16: Kinerja prediksi yang buruk untuk nilai di luar kumpulan data.

Untuk studi kasus lantai ramping, sistem deteksi anomali dasar disiapkan untuk memeriksa validitas data masukan berdasarkan kriteria seleksi berikut:

- ❖ Data masukan berada dalam rentang setiap parameter masukan.
- ❖ Rasio antar parameter penampang berada dalam ambang batas yang ditentukan, yang dapat disimpulkan dari analisis katalog penampang standar Inggris. Misalnya, ketebalan sayap berkorelasi baik dengan ketebalan badan kolom, baik untuk penampang kolom maupun balok. Rasio tersebut berada di antara 0,5–0,85 seperti yang diamati pada histogram pada Gambar 16.17.



Gambar 16.17: Ketergantungan korelasi antara sayap dan ketebalan badan kolom.



Gambar 16.18: Pengaruh ukuran kumpulan data pelatihan terhadap kinerja model.

Pengaruh Ukuran Dataset

Akurasi model berkinerja terbaik dari studi kasus slim-floor dianalisis berdasarkan ukuran data latih. Model dilatih ulang dengan 10 subset data latih yang tersedia yang dipilih secara acak dengan ukuran bervariasi 10%–100%. Setiap model kemudian diuji dengan uji validasi silang yang membentuk 20% dari ukuran sampel awal. Hal ini diulang lima kali untuk setiap subset pelatihan. Selain itu, pelatihan model dilakukan dengan 60 titik data (42% dari data latih yang tersedia) yang secara khusus dipilih agar mendekati batas keputusan potensial setelah pemeriksaan Gambar 16.10. Akurasi rata-rata model pada set validasi silang dan set pelatihan disajikan pada Gambar 16.18. Simpangan baku disajikan dengan arsiran yang lebih terang.

Seperti yang terlihat dari grafik, peningkatan jumlah contoh pelatihan memiliki efek menguntungkan yang kuat untuk meningkatkan akurasi hingga sekitar 100 contoh. Melewati titik ini, keuntungan dari penambahan lebih banyak data pelatihan semakin berkurang. Akurasi model dapat ditingkatkan lebih lanjut dengan memilih secara cermat contoh-contoh pelatihan yang diperkirakan berada dekat dengan batas keputusan. Akurasi 92% dicapai hanya dengan 60 contoh yang telah dipilih sebelumnya. Akurasi serupa dicapai dengan 100 contoh jika dipilih secara acak. Hal ini menunjukkan sifat penting algoritma SVM yang dapat diterapkan pada kumpulan data serupa lainnya—kinerja bergantung pada titik-titik data yang diposisikan paling dekat dengan batas keputusan yang bertindak sebagai fungsi vektor pendukung.

Efek Derau

Kumpulan data yang digunakan dalam kedua studi kasus dihasilkan oleh pemecah FEA deterministik menggunakan parameter masukan berupa pengukuran geometris eksak atau nilai karakteristik konservatif untuk sifat termal yang diambil dari standar teknis Eurocode. Kumpulan data tersebut juga diberi label untuk berbagai kelas insulasi menggunakan nilai ambang batas eksak untuk kenaikan suhu sisi yang tidak terpapar berdasarkan BS EN 1363-1:2012. Oleh karena itu, derau dalam data yang timbul dari distribusi parameter masukan telah dihilangkan pada tahap akuisisi data. Pengujian model ML yang diusulkan pada kumpulan data yang 'lebih derau' berada di luar cakupan studi ini.

Menurut Ng, karena SVM merupakan derau pengklasifikasi berbasis geometris dalam data, SVM hanya mengurangi kinerja model jika ketidakpastian muncul pada titik-titik data yang dekat dengan batas keputusan. Ketidakpastian pada titik-titik data yang jauh dari batas keputusan tidak memengaruhi hasil. Akurasi model dapat ditingkatkan dengan pilihan hiperparameter nilai-C atau fungsi kernel yang tepat.

16.6 KESIMPULAN

Bab ini menjelaskan pendekatan baru penggunaan algoritma pembelajaran mesin SVM sebagai model pengganti untuk melakukan analisis perpindahan panas dalam penilaian rekayasa kebakaran struktural. Proses akuisisi data, analisis data eksploratori, pelatihan model, dan validasi dieksplorasi melalui dua studi kasus. Versi final dari solusi yang diusulkan mencapai tingkat akurasi yang dapat diterima, yaitu 95% dan 96%, masing-masing untuk balok komposit dan studi kasus lantai ramping.

Pendekatan pembelajaran yang diusulkan mencapai akurasi yang memuaskan hanya untuk masukan yang representatif dari kumpulan data yang digunakan untuk melatih model. Pendekatan ini tidak cocok untuk ekstrapolasi ke bagian-bagian di luar rentang yang telah dipelajari. Oleh karena itu, modul tambahan untuk memvalidasi nilai masukan harus dipertimbangkan untuk bagian-bagian di luar rentang yang telah dikembangkan untuk alat ini. Berdasarkan kedua studi kasus tersebut, ditunjukkan bahwa pendekatan ML yang diusulkan akan sesuai untuk aplikasi rekayasa kebakaran struktural karena:

- (1) memungkinkan prediksi respons termal dan peringkat ketahanan api yang cepat dengan akurasi yang memadai yang dibutuhkan untuk studi awal/konseptual
- (2) dapat menghasilkan tingkat keandalan prediksi yang tinggi dan terukur
- (3) tidak memerlukan penyederhanaan geometri input FEA tingkat lanjut sebelumnya
- (4) tidak memerlukan komputasi yang mahal dan tidak memerlukan keahlian khusus dalam pemodelan numerik setelah pembuatan dataset awal dan pelatihan model ML
- (5) dapat dengan mudah diimplementasikan dalam studi optimasi awal dan untuk memberikan masukan bagi model yang lebih detail.

BAB 17

AI UNTUK PREDIKSI SIFAT MEKANIK BETON ULTRA-HIGH PERFORMANCE

17.1 PENDAHULUAN

Beton kinerja ultra tinggi (UHPC) adalah jenis beton canggih dengan kekuatan tekan dan tarik, daya tahan, daktilitas (pasca-retak), dan sifat penyerapan energi yang lebih baik dibandingkan dengan beton konvensional. Untuk mencapai sifat-sifat yang ditingkatkan ini, campuran batch UHPC dirancang dengan rasio air-terhadap-pengikat yang rendah, mengandung serat baja dan campuran dengan kehalusan tinggi, serta memerlukan prosedur pencampuran khusus dan perawatan suhu tinggi. Karena desain campuran dan prosedur fabrikasinya yang unik, struktur mikro UHPC berbeda dari beton konvensional, yang pada dasarnya menghasilkan peningkatan kinerja mekanik. Berkat sifat-sifatnya yang unggul, UHPC semakin diminati untuk membangun struktur yang lebih ramping, estetis, dan tahan lama.

Komponen struktur, ketika digunakan dalam bangunan, harus memenuhi persyaratan ketahanan api karena keselamatan kebakaran merupakan salah satu pertimbangan utama dalam desain bangunan. Struktur beton yang terbuat dari beton mutu normal (BKN) tradisional menunjukkan ketahanan api yang sangat baik tanpa memerlukan langkah-langkah proteksi kebakaran tambahan. Hal ini disebabkan oleh konduktivitas termal yang rendah dan kapasitas termal BKN yang tinggi, serta degradasi kekuatan dan modulusnya yang lebih lambat terhadap suhu. Namun, studi terbaru menunjukkan bahwa komponen struktur yang dibuat menggunakan UHPC tidak menunjukkan tingkat ketahanan api yang sama dengan komponen yang dibuat menggunakan beton tradisional. Hal ini terutama disebabkan oleh degradasi sifat mekanik UHPC yang lebih cepat terhadap suhu, serta kerentanannya yang tinggi terhadap pengelupasan akibat api.

Pengelupasan menyebabkan hilangnya bagian beton dari komponen struktur, yang pada gilirannya mengakibatkan peningkatan laju perpindahan panas dan selanjutnya meningkatkan laju kerusakan sifat mekanik. Biasanya, suhu penampang pada anggota struktur beton di bawah kebakaran bangunan berada dalam kisaran 20–800°C. Oleh karena itu, untuk menilai ketahanan api suatu anggota secara analitis, pengetahuan tentang variasi sifat material diperlukan dalam rentang suhu tersebut.

Sifat mekanis yang menjadi perhatian utama dalam evaluasi ketahanan api anggota UHPC adalah kuat tekan, modulus elastisitas, dan kuat tarik. Biasanya, hanya kuat tekan dan modulus elastisitas yang disertakan dalam perhitungan ketahanan api anggota NSC tradisional, sedangkan kuat tarik diabaikan. Hal ini disebabkan oleh fakta bahwa kuat tarik NSC konvensional jauh lebih rendah daripada kuat tekannya (Khaliq dan Kodur, 2011). Di sisi lain, kuat tarik UHPC tidak dapat diabaikan dari perhitungan kekuatan karena memiliki kuat tarik yang jauh lebih tinggi daripada NSC, dan berkontribusi pada pencapaian kapasitas anggota yang lebih tinggi. Selain itu, kuat tarik sangat penting dalam mengendalikan perambatan retak

pada beton. Lebih jauh lagi, kekuatan tarik merupakan sifat penting dalam kondisi kebakaran karena membantu menahan keretakan akibat kebakaran.

Sifat mekanis semua jenis beton memburuk pada suhu tinggi akibat perubahan mikrostruktur akibat suhu, yang terutama dipengaruhi oleh kadar air, proporsi campuran, dan volume bahan tambahan dalam beton. Sifat mekanis suhu tinggi telah dipelajari secara ekstensif untuk beton non-semen (NSC) dan beton mutu tinggi (HSC). Hubungan sifat kodal beton yang bergantung pada suhu yang paling banyak diadopsi ditetapkan oleh Manual ASCE (1992) dan Eurocode 2. Namun, hubungan ini dikembangkan pada tahun 1990-an–2000-an dengan menguji beton konvensional, sehingga tidak ada model yang ditetapkan untuk ketergantungan suhu terhadap sifat mekanis UHPC.

Selain itu, tidak ada metode dan prosedur uji standar untuk mengukur sifat mekanis semua jenis beton, termasuk UHPC, pada suhu tinggi (Kodur dkk., 2020). Oleh karena itu, sifat mekanik suhu tinggi UHPC dalam penelitian yang dipublikasikan telah dievaluasi menggunakan pengaturan dan prosedur pengujian yang tidak konsisten, termasuk laju pemanasan, ukuran spesimen, proporsi campuran beton, dll. Hal ini menyebabkan beragamnya variasi data uji yang tersedia mengenai sifat mekanik suhu tinggi UHPC dalam literatur. Oleh karena itu, model terpadu untuk menggambarkan degradasi kekuatan dan modulus akibat suhu pada UHPC saat ini masih kurang.

Sejak dekade terakhir, teknik berbasis kecerdasan buatan (AI) dan pembelajaran mesin (ML) semakin banyak diterapkan untuk memecahkan masalah rumit di bidang teknik struktur. Beberapa aplikasi utamanya berada di bidang pemodelan dan prediksi sifat material serta pemantauan kesehatan struktur. AI telah terbukti mampu memecahkan berbagai masalah yang beragam dan kompleks dengan meniru kemampuan kognitif manusia untuk melakukan tugas secara cerdas. Implementasi perangkat AI inovatif ini efisien dari segi biaya dan waktu karena model AI tidak melibatkan pengaturan eksperimen yang rumit atau eksekusi model numerik yang rumit dengan beberapa parameter.

Mayoritas studi UHPC yang menerapkan AI dalam literatur berfokus pada optimasi desain campuran, prediksi kuat tekan, dan evaluasi kapasitas anggota pada suhu ruang. Terdapat beberapa studi berbasis AI yang ditujukan untuk mengembangkan model sifat material suhu tinggi untuk material konstruksi, tetapi dengan konsentrasi terbatas pada UHPC. Berdasarkan hal ini, makalah ini berhipotesis bahwa AI dapat berfungsi sebagai solusi potensial untuk mendapatkan model sifat mekanik suhu tinggi terpadu yang akurat untuk UHPC. Untuk mengembangkan hubungan sifat ini, studi eksperimental yang dipublikasikan tentang uji sifat mekanik suhu tinggi pada UHPC dalam literatur ditinjau dan semua data uji dari studi ini dikompilasi. Basis data properti material UHPC yang telah dihimpun kemudian dianalisis menggunakan integrasi jaringan saraf tiruan (JST) dan pemrograman genetik (GP).

Analisis berbasis AI ini digunakan untuk melacak hilangnya properti mekanis pada suhu tinggi dan mengembangkan ekspresi matematika yang disederhanakan untuk menangkap degradasi yang disebabkan oleh suhu ini pada UHPC. Bagian berikut menyajikan langkah-langkah yang terlibat dalam pengembangan hubungan properti mekanis suhu tinggi berbasis AI untuk UHPC dalam rentang suhu 20–800°C.

17.2 SIFAT MEKANIK UHPC YANG BERGANTUNG PADA SUHU

Sifat mekanik yang penting untuk evaluasi ketahanan api beton adalah kuat tekan ($f'c$), kuat tarik (ft), dan modulus elastisitas (E). Basis data untuk UHPC dikembangkan dengan mengkompilasi hasil dari sejumlah uji sifat mekanik suhu tinggi yang diperoleh dari literatur terbuka untuk membuat model AI. UHPC umumnya terbuat dari serat baja, yang berkontribusi terhadap keuletan pascaretak dan sifat kekuatan tariknya yang tinggi. Beberapa campuran UHPC juga mengandung serat polipropilena (PP) selain serat baja, untuk mencegah spalling akibat kebakaran dengan meningkatkan permeabilitas beton pada suhu tinggi.

Tinjauan literatur menunjukkan bahwa keberadaan serat polipropilena saja dalam UHPC tidak secara signifikan memengaruhi variasi degradasi kekuatan relatif dan modulus pada suhu tinggi. Basis data ini dihasilkan dengan mengkompilasi uji properti pada campuran UHPC yang hanya mengandung serat baja serta campuran UHPC yang mengandung serat baja dan polipropilena, karena efek yang tidak signifikan terhadap varians properti. Perlu dicatat bahwa spesimen UHPC tanpa serat baja tidak dipertimbangkan karena tidak memenuhi karakteristik daktail dan tarik khas UHPC.

Untuk mengukur sifat mekanis beton pada suhu ruang, prosedur uji khusus telah ditetapkan dengan baik dalam standar pengujian. Sebaliknya, standar pengujian saat ini tidak menetapkan panduan apa pun pada suhu tinggi mengenai prosedur uji, peralatan, atau parameter untuk mengevaluasi sifat mekanis beton. Menambah kompleksitas ini, tiga jenis metode pengujian yang berbeda dapat diikuti untuk menilai sifat mekanis beton pada suhu tinggi: tanpa tegangan, tegangan, dan residual.

Sesuai dengan metode pengujian tanpa tegangan, spesimen dipanaskan hingga suhu target yang telah ditentukan tanpa memberikan beban awal apa pun. Setelah spesimen mencapai suhu yang seragam secara menyeluruh, pembebanan akan diberikan pada spesimen hingga spesimen tersebut gagal. Dalam metode pengujian tegangan, spesimen diberi beban awal sebelum pemanasan, dan beban awal tersebut dipertahankan selama fase pemanasan. Spesimen kemudian dibebani hingga gagal setelah mencapai kesetimbangan termal. Sesuai dengan metode pengujian residual, spesimen dipanaskan hingga suhu target (dengan atau tanpa beban awal) hingga mencapai kondisi tunak.

Setelah suhu spesimen stabil, spesimen dibiarkan mendingin hingga suhu sekitar dan kemudian spesimen dibebani hingga gagal. Sementara metode pengujian tegangan dan tanpa tegangan mensimulasikan perilaku beton yang dipanaskan selama kebakaran, metode pengujian residual merepresentasikan perilaku beton setelah pendinginan setelah terpapar kebakaran. Meskipun pengukuran sifat bergantung pada pengaturan dan kondisi pengujian, standar pengujian tidak memberikan panduan apa pun mengenai detail prosedur pengujian untuk semua metode penilaian yang disebutkan di atas.

Untuk tujuan ini, para peneliti telah mengikuti berbagai prosedur pengujian non-standar dan kondisi spesimen (seperti variasi ukuran dan bentuk sampel, laju pemanasan, tingkat beban, dan laju pembebanan) untuk melakukan studi suhu tinggi dalam literatur. Karena para peneliti menggunakan penilaian mandiri untuk memilih dan menerapkan

prosedur evaluasi non-standar, terdapat variasi yang signifikan dalam hasil uji terukur untuk karakterisasi sifat mekanik beton pada suhu tinggi.


Data uji yang dilaporkan mengenai variasi kuat tekan terhadap suhu dikompilasi untuk UHPC dan diplot pada Gambar 17.1 beserta relasi kodal dan yang umum digunakan (Eurocode 2; manual ASCE; Kodur dkk., 2008) untuk NSC dan HSC. Secara keseluruhan, kuat tekan UHPC menurun seiring peningkatan suhu. Dapat dicatat dari Gambar 17.1 bahwa dalam beberapa penelitian, peningkatan awal kuat tekan terjadi hingga suhu 200°C, diikuti oleh tren penurunan seiring peningkatan suhu lebih lanjut. Peningkatan kuat tekan UHPC ini setelah pemanasan awal hingga 200°C disebabkan oleh selesainya reaksi pozolan dan hidrasi produk semen tak terhidrasi dalam struktur mikro.

Lebih lanjut, terdapat rentang variasi yang signifikan dalam kuat tekan UHPC yang terukur pada suhu tinggi. Hal ini terutama disebabkan oleh penerapan berbagai pengaturan dan prosedur pengujian, termasuk ukuran spesimen, laju pemanasan, dan proporsi campuran beton. Misalnya, Tai dkk. (2011) menguji silinder 50x100 mm dengan pemanasan pada laju 2°C/menit mengikuti rezim pengujian residual, sedangkan Abid dkk. (2019) menguji kubus 70x70x70 mm dengan pemanasan pada laju 5°C/menit mengikuti rezim evaluasi tanpa tekanan. Selain variasi signifikan dalam data uji yang dikumpulkan dari studi oleh berbagai peneliti, model material yang diadopsi oleh Eurocode 2 dan manual ASCE juga menunjukkan disparitas substansial di antara model masing-masing serta dengan data uji UHPC.

Data uji yang dipublikasikan pada modulus elastisitas yang bergantung pada suhu untuk UHPC diplot pada Gambar 17.2 bersama dengan hubungan Eurocode 2 dan manual ASCE untuk NSC. Data yang dikompilasi menunjukkan bahwa modulus elastisitas UHPC menurun dengan cepat dengan kenaikan suhu. Lebih sedikit studi telah dilakukan pada variasi modulus elastisitas UHPC dengan suhu dibandingkan dengan jumlah studi yang difokuskan pada menangkap variasi kekuatan tekan. Serupa dengan data kuat tekan, disparitas dapat diamati pada kehilangan modulus elastisitas yang terukur seiring dengan perubahan suhu. Karena jumlah titik data yang lebih sedikit, fluktuasi modulus elastisitas tampak lebih kecil.

Perbedaan masih terdapat dalam prosedur pengujian modulus elastisitas untuk UHPC pada suhu tinggi, misalnya Zheng dkk. (2012) yang mengukur modulus elastisitas menggunakan prisma 70x70x228 mm yang mengalami laju pemanasan 4°C/menit mengikuti rezim uji residual, sementara Banerji dan Kodur (2021) menggunakan silinder 75x150 mm dengan laju pemanasan 2°C/menit mengikuti rezim penilaian tanpa tekanan.

Data uji yang dikompilasi mengenai kuat tarik suhu tinggi UHPC, serta relasi manual Eurocode 2 dan ASCE untuk NSC, disajikan pada Gambar 17.3.




Gambar 17.1: Data kompilasi tentang variasi kekuatan tekan UHPC terhadap suhu.


Kekuatan tarik beton dapat dievaluasi dalam tiga bentuk: lentur, langsung, dan pecah. Kekuatan tarik lentur melibatkan pembebanan lentur titik ketiga pada balok beton kecil (prisma). Kekuatan tarik langsung dapat diukur melalui pengujian spesimen dogbone dengan memberikan beban tarik aksial pada mesin uji yang sesuai hingga sampel putus akibat tarikan langsung. Kekuatan tarik pecah dievaluasi dengan memberikan beban tekan diametris pada spesimen beton silinder sepanjang panjangnya hingga terjadi kegagalan akibat pecahnya spesimen sepanjang diameter vertikal.

Akibat penerapan prosedur pengujian yang berbeda tanpa adanya pedoman standar, terdapat variasi yang signifikan dalam data uji terukur dari studi yang dilaporkan, seperti yang dapat dilihat pada Gambar 17.3. Sebagai contoh, Li dan Liu (2016) menguji spesimen dogbone 150x75 mm dengan pemanasan pada suhu 4°C/menit di bawah rezim uji residual, dan Chadli dkk. (2021) menguji prisma 40x40x160 mm dengan pemanasan pada 3°C/menit setelah uji tanpa tekanan.

Selain varians yang disebutkan sebelumnya dalam data yang dikumpulkan terkait dengan ukuran spesimen, laju pemanasan, dan uji tanpa tekanan, inkonsistensi dalam hasil uji yang dikumpulkan juga dapat dikaitkan dengan faktor-faktor tambahan. Campuran UHPC biasanya dirancang untuk mengandung serat baja agar mencapai karakteristik kekuatan tarik tinggi dan sifat daktilitas yang lebih baik.



Gambar 17.2: Data kompilasi tentang variasi modulus elastisitas UHPC terhadap suhu.



Gambar 17.3: Data kompilasi variasi kekuatan tarik UHPC terhadap suhu.

Namun, belum ada rekomendasi yang ditetapkan mengenai jumlah serat baja dalam campuran UHPC. Akibatnya, berbagai dosis serat baja telah ditambahkan ke dalam campuran UHPC di berbagai eksperimen dalam literatur, yang mengakibatkan variasi dalam degradasi sifat mekanik akibat suhu yang terukur. Demikian pula, beberapa penelitian juga menambahkan serat polipropilena selain serat baja untuk mencegah spalling akibat kebakaran. Karena kurangnya panduan, dosis serat polipropilena bervariasi di seluruh studi yang dilaporkan, yang menyebabkan variasi dalam laju kerusakan sifatnya. Lebih lanjut, pengeringan uap sangat penting selama fabrikasi UHPC untuk memfasilitasi hidrasi sempurna produk semen dan

pengembangan sifat mekanik superior pada UHPC, meskipun banyak studi eksperimental yang dilaporkan mengabaikannya.

Terakhir, beberapa uji sifat mekanik suhu tinggi pada UHPC mengeringkan spesimen uji dalam oven sebelum memanaskannya untuk uji sifat di dalam tungku. Prosedur pra-pengeringan oven tersebut diterapkan untuk menghilangkan kelembapan dari spesimen guna meminimalkan risiko spalling akibat kebakaran. Namun, pengeringan pra-oven bukanlah prosedur uji standar dan dapat memperburuk anomali dalam data yang diukur.

Variasi yang besar dalam data uji yang dikumpulkan dapat menyebabkan prediksi yang berlebihan atau prediksi yang kurang terhadap ketahanan api suatu komponen UHPC. Prediksi yang berlebihan dapat menyebabkan desain rekayasa yang tidak aman, sementara prediksi yang kurang dapat mengakibatkan desain struktural yang tidak ekonomis. Untuk menghilangkan ambiguitas dalam penilaian ketahanan api, diperlukan relasi sifat terpadu untuk memprediksi sifat mekanik suhu tinggi UHPC.

Untuk mewujudkan hal ini, studi ini bertujuan untuk mengembangkan hubungan yang disederhanakan dan bergantung pada suhu untuk setiap sifat mekanik UHPC dengan menggunakan model AI pada data uji yang dikumpulkan. Model material dalam kode desain tidak dipertimbangkan dalam analisis AI ini karena dikembangkan menggunakan uji sifat yang dilakukan pada beton konvensional. Detail pengembangan model AI dan analisisnya dijelaskan pada bagian berikut.


17.3 PENGEMBANGAN MODEL KECERDASAN BUATAN

AI memanfaatkan algoritma untuk mengungkap pola dalam kumpulan data kompleks dengan mereplikasi proses kognitif yang diterapkan manusia untuk pemecahan masalah. Dalam studi ini, kombinasi ANN dan GP diterapkan untuk mengembangkan model AI guna merumuskan hubungan sifat mekanik yang bergantung pada suhu untuk UHPC. Model hibrida ANN-GP serupa telah digunakan dalam literatur untuk menurunkan model sifat material untuk material teknik sipil lainnya.

ANN dikembangkan menggunakan MATLAB[®] dan terstruktur sebagai feedforward, di mana neuron-neuron diorganisasikan menjadi tiga lapisan: masukan, tersembunyi, dan keluaran seperti yang diilustrasikan pada Gambar 17.4. Neuron di semua lapisan selanjutnya saling terhubung. Untuk penelitian ini, lapisan masukan terdiri dari faktor reduksi yang dikumpulkan dari data uji yang dipublikasikan untuk sifat kekuatan dan modulus UHPC pada berbagai suhu tinggi. Lapisan masukan kemudian dihubungkan ke 10 lapisan tersembunyi dan bobot ditetapkan secara internal untuk setiap koneksi. Bobot dikalikan dengan data masukan untuk mengaktifkan fungsi transfer (seperti fungsi sigmoid) dan keluaran yang ditransformasikan dijumlahkan untuk menghasilkan jawaban akhir dari lapisan keluaran. Performa jaringan saraf tiruan yang dikembangkan ditentukan dengan membandingkan prediksinya dengan nilai terukur dari uji suhu tinggi yang dilaporkan. Perbandingan tersebut diukur dan diadaptasi dengan pembelajaran melalui beberapa iterasi untuk setiap sifat mekanik hingga performa ANN memuaskan.

Setelah model ANN untuk suatu sifat dikembangkan, model tersebut diekspor sebagai fungsi MATLAB dan diformulasikan menjadi ekspresi matematika melalui GP berbasis pohon menggunakan perangkat lunak sumber terbuka, Heuristic Lab. Analisis GP melibatkan pembuatan populasi acak solusi potensial yang secara simbolis berbentuk pohon ekspresi, yang terdiri dari simpul pohon dan simpul terminal (daun). Simpul pohon berisi operator (penjumlahan, pembagian, dll.) atau fungsi (log, pangkat, dll.) sedangkan simpul terminal berisi variabel (a, b, c, dll.) atau konstanta.

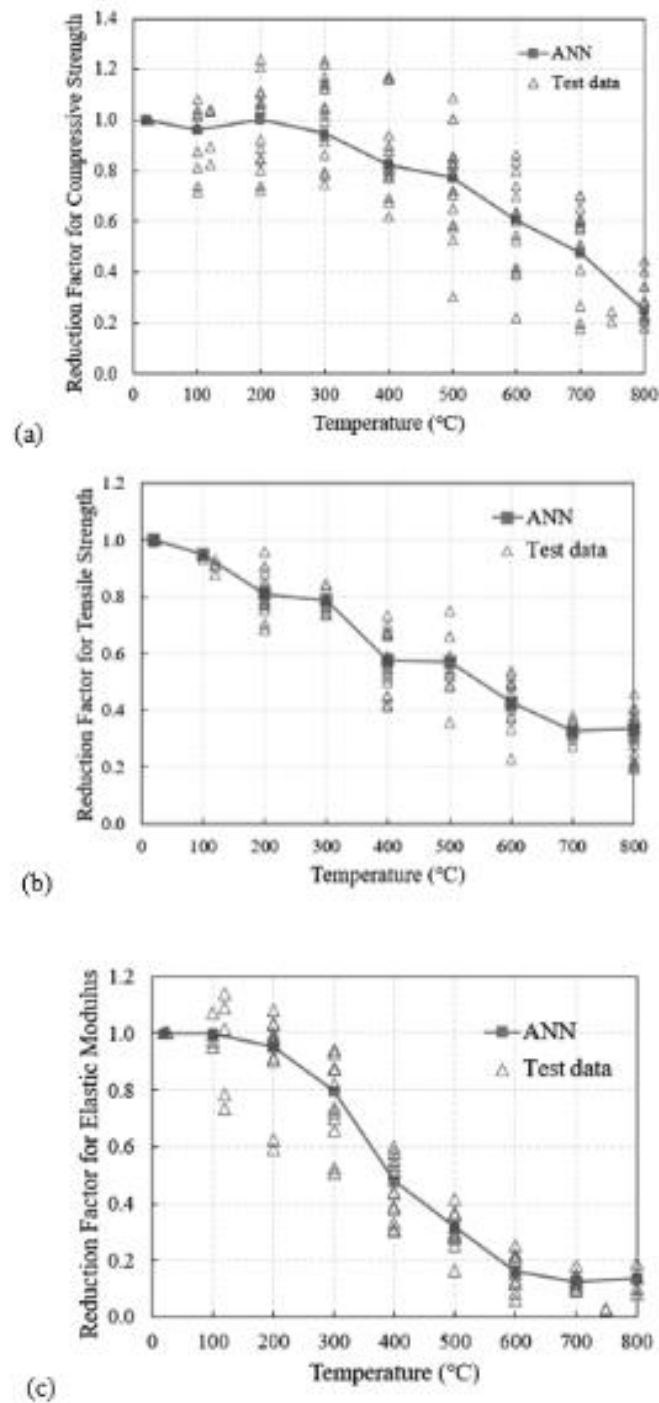
Ekspresi untuk menangkap data properti apa pun direpresentasikan dalam struktur pohon dan dianalisis secara rekursif untuk menghasilkan ekspresi multivariat dengan kebugaran yang lebih baik di setiap iterasi. Prosedur rekursif analisis GP ini menggunakan algoritma, berdasarkan fundamental evolusi biologis, yang menggabungkan mutasi acak, persilangan, dan evolusi yang menghasilkan ekspresi yang paling sesuai (survival). Akhirnya, kinerja relasi properti yang diturunkan dari GP dinilai dengan membandingkannya dengan nilai masukan seperti yang diprediksi dari model ANN yang dikembangkan.



Gambar 17.4 Tata letak jaringan saraf tiruan (ANN).

17.4 DERIVASI MODEL PROPERTI MEKANIK

Titik data terukur yang berkaitan dengan faktor reduksi kekuatan tekan, modulus elastisitas, dan kekuatan tarik (misalnya, 1, 0,96, 0,87, dll.) untuk UHPC pada berbagai titik suhu dalam rentang 20–800°C (misalnya, 20°C, 100°C, 200°C, dll.) merupakan masukan ke model ANN. Data input terdiri dari 406 titik data yang dikumpulkan dari studi eksperimental dalam literatur terbuka seperti yang dibahas di Bagian 2.



Gambar 17.5: Perbandingan antara sifat yang diperoleh dari AI dan sifat yang diukur: (a) Kuat tekan; (b) Kuat tarik; (c) Modulus elastisitas.

Model material yang direkomendasikan oleh kode desain (ASCE dan Eurocode 2) tidak dimasukkan ke dalam ANN karena model ini diturunkan beberapa dekade lalu dengan melakukan uji kekuatan suhu tinggi pada jenis beton konvensional (seperti beton dengan kekuatan normal) dan tidak menyertakan pengukuran apa pun pada UHPC.

Set data input yang dikompilasi dibagi secara acak menjadi tiga bagian: 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk menguji ANN yang dikembangkan. ANN yang berhasil dilatih diaplikasikan untuk merumuskan model sifat material mekanis yang

bergantung pada suhu yang digeneralisasi. Prediksi dari ANN diplot bersama dengan data terukur untuk setiap sifat mekanis UHPC pada Gambar 17.5 yang menunjukkan bahwa ANN berhasil menangkap tren terintegrasi faktor reduksi dengan suhu dan nilai prediksi ANN berada dalam kisaran data uji yang dikompilasi.

Kinerja model ANN juga dievaluasi dengan menghitung dua metrik kebugaran statistik. Metrik pertama adalah galat kuadrat rata-rata (MSE) yang didefinisikan sebagai:

$$MSE = \frac{1}{z} \sum_{i=1}^z (m_i - p_i)^2 \quad (17.1)$$

di mana z = jumlah total titik data, m_i = keluaran terukur ke- i , dan p_i = keluaran terprediksi ke- i . Metrik evaluasi kinerja kedua adalah koefisien determinasi (R^2) dan dapat dihitung sebagai:

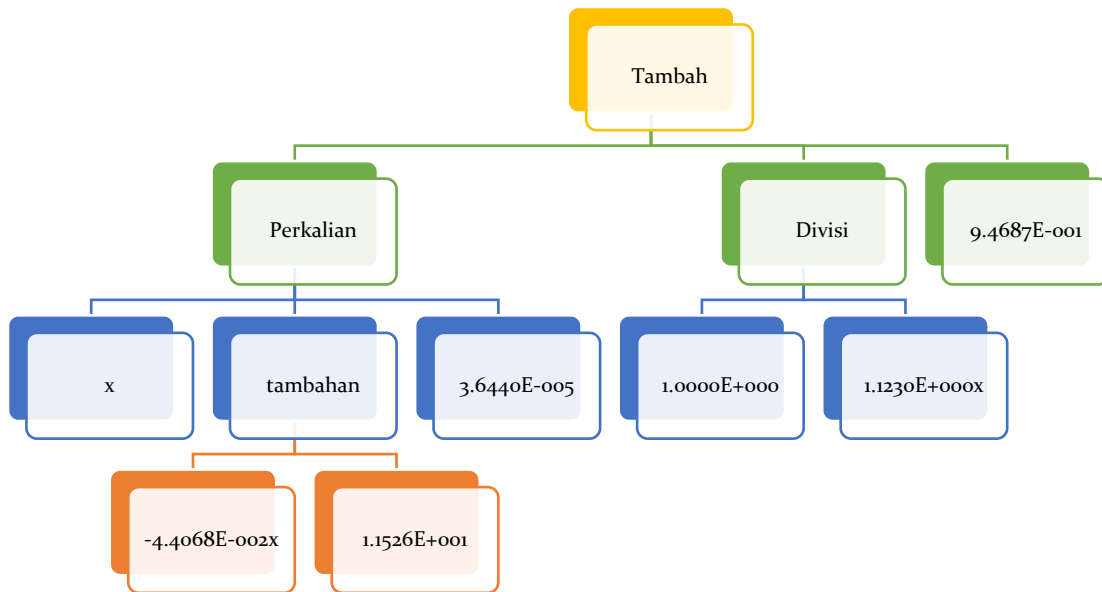
$$R^2 = \frac{\sum_i (p - \frac{1}{z} \sum_{i=1}^z m)^2}{\sum_i (m - \frac{1}{z} \sum_{i=1}^z m)^2} \quad (17.2)$$

di mana z = jumlah total titik data, i = nomor masukan, m = keluaran terukur, dan p = keluaran terprediksi. Nilai MSE yang lebih rendah dan nilai R^2 yang lebih tinggi menunjukkan kinerja yang baik. Nilai MSE dan R^2 yang dihitung untuk ANN yang dikembangkan ditunjukkan pada Tabel 17.1, di mana metrik evaluasi kinerja tersebut menunjukkan bahwa ANN yang dikembangkan sesuai dengan data terukur dan layak digunakan untuk melacak degradasi pada sifat mekanis UHPC yang bergantung pada suhu. Kinerja model ANN dapat ditingkatkan lebih lanjut dengan menggunakan kumpulan data yang lebih besar, yang memerlukan pengujian dan upaya penelitian tambahan. Berdasarkan pengujian dan validasi ini, ANN yang dikembangkan dianggap layak untuk menyusun persamaan model sifat mekanis yang bergantung pada suhu dengan tingkat keyakinan yang memadai.

Tabel 17.1: Metrik kinerja yang diperoleh melalui ANN.

Kinerja	R ²	MSE
Kekuatan tekan	91.82	0.0043
Kekuatan tarik	93.41	0.0044
Modulus elastis	93.45	0.0091

Kinerja model ANN dapat ditingkatkan lebih jauh dengan menggunakan kumpulan data yang lebih besar, yang memerlukan upaya pengujian dan penelitian tambahan. Berdasarkan pengujian dan validasi ini, ANN yang dikembangkan dianggap sesuai untuk mengembangkan ekspresi untuk model sifat mekanis yang bergantung pada suhu dengan keyakinan.



Gambar 17.6: Regresi simbolik menggunakan pemrograman genetik (GP) untuk mendapatkan ekspresi terpadu untuk kuat tekan UHPC (x adalah Suhu dalam °C).

Tabel 17.2: Ekspresi turunan GP untuk faktor reduksi sifat mekanik UHPC.

Properti	Ekspresi yang Diterima	R ² (%)
Kekuatan tekan	$-160584 * 10^{-6}T^{-4}T + \frac{1}{1.123T} + 0.94687$	99.26
Kekuatan tarik	$-0.00089267T + \frac{1}{-0.37299T + 135.13} + 1.0057$	98.43
Modulus elastis	$7.5598 * 10^{-9}T^3 - 8.9033 * 10^{-6}T^2 + 1.2608 * 10^{-3}T + 0.97514$	99.33

Prediksi dari model ANN dipasang ke dalam ekspresi simbolik nonlinier menggunakan algoritma GP berbasis pohon. Pohon ekspresi awal dari analisis GP rumit dan panjang. Iterasi dan operasi penyederhanaan dilakukan untuk mengompresi pohon ekspresi guna memperoleh hubungan sifat mekanik yang ringkas dan mudah digunakan.

Sebagai ilustrasi, hasil yang disederhanakan dari analisis GP dalam representasi simbolik untuk kuat tekan suhu tinggi disajikan pada Gambar 17.6. Node-node pohon ekspresi dirangkai bersama untuk memperoleh hubungan sifat. Ekspresi sifat mekanik bergantung suhu terpadu yang diperoleh dari analisis GP tercantum dalam Tabel 17.2, beserta koefisien determinasinya (R²). Ekspresi yang dihasilkan untuk kuat tekan, kuat tarik, dan sifat modulus elastisitas memiliki nilai R² yang tinggi (seperti yang ditunjukkan pada Tabel 17.2) yang menyiratkan keakuratan persamaan yang diusulkan ini.

17.5 TANTANGAN SAAT INI DAN PENELITIAN MENDATANG

Untuk perhitungan kinerja tahan api yang realistis pada komponen UHPC, sifat mekanik suhu tinggi UHPC yang andal harus digunakan. Saat ini, terdapat kekurangan ekspresi yang disederhanakan dalam kode desain tahan api untuk kekuatan suhu tinggi dan sifat modulus elastisitas UHPC. Selain itu, terdapat perbedaan yang cukup besar dalam model material yang

diusulkan dalam literatur yang tersedia karena adanya variasi dalam proses fabrikasi yang diadopsi dan metode pengujian suhu tinggi (termasuk metode pengujian, pengaturan pengujian, bentuk dan ukuran spesimen, laju pemanasan dan pembebanan, dll.).

Akibatnya, sulit bagi peneliti atau praktisi kebakaran untuk mengadopsi model material tertentu guna melakukan evaluasi ketahanan api yang tepat. Untuk menjembatani kesenjangan pengetahuan ini dan memfasilitasi desain tahan api struktur UHPC, penelitian saat ini menunjukkan penerapan model AI untuk mengembangkan hubungan sifat mekanik suhu tinggi yang terpadu. Namun, terdapat beberapa kendala dalam skenario implementasi AI saat ini untuk menurunkan sifat material UHPC.

Pelatihan dan kinerja model AI yang tepat sangat bergantung pada ukuran set data yang dipilih. Tantangan yang dihadapi dalam penelitian ini adalah karena UHPC merupakan jenis beton yang relatif baru, jumlah data uji yang tersedia untuk UHPC lebih sedikit dibandingkan dengan jumlah data yang tersedia untuk jenis beton konvensional yang telah diteliti secara lebih mendalam, seperti NSC dan HSC. Meskipun model AI yang dikembangkan dalam penelitian ini dianggap mampu memberikan model sifat mekanik yang akurat, hasil yang diperoleh kemungkinan dapat disempurnakan dengan menambahkan lebih banyak titik data uji ke dalam basis data yang ada melalui upaya pengujian lebih lanjut di masa mendatang.

Melakukan investigasi sifat pada suhu tinggi merupakan hal yang kompleks dan membutuhkan upaya serta sumber daya yang signifikan. Kompleksitas ini semakin meningkat karena belum adanya metode uji standar untuk melakukan penilaian sifat mekanik beton pada suhu tinggi. Hal ini menyebabkan tantangan lain berupa ketidakseragaman substansial dalam data yang dikumpulkan akibat perbedaan kondisi dan prosedur uji yang diikuti dalam uji sifat mekanik yang dilaporkan sebagaimana telah dibahas sebelumnya. Untuk mencapai keseragaman yang lebih baik dalam hasil yang diperiksa, standar uji perlu dirancang untuk mengukur sifat mekanik UHPC pada suhu tinggi.

17.6 KESIMPULAN

Penelitian ini menerapkan model AI yang melibatkan ANN dan GP untuk menghasilkan model sifat mekanik UHPC yang bergantung pada suhu pada rentang suhu 20–800°C. Sifat mekanik yang dipelajari meliputi kuat tekan, kuat tarik, dan modulus elastisitas. Kesimpulan berikut dapat ditarik dari makalah ini:

- ❖ Standardisasi prosedur pengujian untuk menilai sifat mekanik UHPC yang bergantung pada suhu sangat mendesak, demikian pula eksperimen lebih lanjut di masa mendatang, guna menyusun basis data yang lebih konsisten dan kaya.
- ❖ Model ANN yang dikembangkan mampu memahami dan mengekspresikan laju penurunan sifat mekanik UHPC pada suhu tinggi.
- ❖ Model GP yang diusulkan dapat dengan tepat menghasilkan ekspresi sederhana yang digeneralisasi untuk sifat mekanik UHPC pada suhu tinggi.
- ❖ Hubungan sifat mekanik yang dikembangkan dapat digunakan untuk tujuan desain praktis dalam mengevaluasi ketahanan api struktur UHPC.

BAB 18


MANAJEMEN TEROWONGAN CERDAS BERBASIS AI DAN SENSOR

18.1 PENDAHULUAN

Terowongan telah memainkan peran penting dalam sistem transportasi modern sejak pertengahan abad ke-20, berkat utilitas dan fleksibilitasnya yang tinggi di wilayah pegunungan serta efektivitasnya dalam mengatasi keterbatasan lahan di wilayah metropolitan yang padat. Pembangunan ruang bawah tanah dan terowongan telah menjadi pilihan yang menguntungkan, terutama di negara-negara berkembang pesat di Asia. Terowongan jalan raya, kereta api, dan bawah tanah ini membantu memenuhi permintaan yang meningkat akan sistem transportasi perkotaan yang lebih efisien bagi kota-kota besar dengan kepadatan penduduk yang tinggi.

Saat ini, meskipun probabilitas insiden kebakaran bangunan lebih kecil, jumlah absolut kecelakaan kebakaran terowongan tahunan masih sangat tinggi, mengingat ribuan terowongan di seluruh dunia, kepadatan lalu lintas yang tinggi, dan kecelakaan. Karena terowongan merupakan ruang yang panjang dan sulit dievakuasi, kebakaran terowongan dapat berakibat fatal dan menyebabkan kerugian ekonomi yang sangat besar. Pada tahun 1995, sebuah insiden kebakaran terowongan yang dahsyat di Azerbaijan disebabkan oleh gangguan listrik dan akhirnya menyebabkan 289 kematian dan banyak korban luka (Gambar 18.1a). Pada tahun 2020, kebakaran terjadi pada kereta yang sedang naik di terowongan kereta kabel Gletscherbahn Kaprun 2 di Kaprun, Austria dan menewaskan 155 orang (Gambar 18.1b).

Pada tahun 2014, sebuah truk batu bara bertabrakan dengan truk tangki metanol di dalam Terowongan Yanhou, Tiongkok. Api metanol cair memicu penyebaran api yang cepat dan serangkaian ledakan, yang menyebabkan lebih dari 30 kematian (Gambar 18.1c). Pada tahun 2020, kecelakaan kebakaran terjadi di Terowongan Samae 2, Korea, setelah tabrakan puluhan tank dan truk, yang menewaskan empat orang dan melukai lebih dari 40 lainnya (Gambar 18.1d). Tabel 18.1 mencantumkan beberapa kecelakaan kebakaran terowongan parah baru-baru ini yang menyebabkan lebih dari 30 kematian, dan basis data kecelakaan kebakaran terowongan yang lebih rinci tersedia daring.



Gambar 18.1: Kecelakaan kebakaran terowongan tragis yang terkenal, (a) Kebakaran Metro Baku, Azerbaijan, 1995, (b) Bencana Kebakaran Kaprun, Austria, 2000, (c) Kebakaran Terowongan Yanhou, Tiongkok, 2014, dan (d) Kebakaran Terowongan Samae 2, Korea, 2020.

Tabel 18.1: Beberapa kecelakaan kebakaran terowongan besar dengan korban jiwa yang parah selama 50 tahun terakhir.

Tahun	Lokasi Terowongan	Jenis Kecelakaan	Korban Jiwa
1972	Terowongan Hokuriku, Jepang	Korsleting Listrik	744
1983	Pecrile, Italia	Tabrakan	31
1984	Terowongan San Benedetto, Italia	Serangan Bom	137
1995	Kereta Bawah Tanah Baku, Azerbaijan	Kerusakan Listrik	289
1999	Mont Blanc, Prancis-Italia	Kebocoran Oli Motor	39
1999	Terowongan Tauren, Austria	Tabrakan Beruntun Multi-Kendaraan	61
2000	Gletscherbahn Kaprun, Austria	Pemanas Kipas Listrik	155
2003	Vicenza, Italia	Bus Terbalik	56
2003	Kereta Bawah Tanah Daegu, Korea Sel.	Kebakaran Kereta Bawah Tanah	340
2010	Terowongan Huishan, Tiongkok	Pembakaran Sengaja	43
2014	Yanhou, Tiongkok	Tabrakan	31
2019	Terowongan Maoliling, Tiongkok	Penyalan Mandiri Ban	36
2020	Terowongan Samae 2, Korea	Tabrakan	47

Seringnya kebakaran terowongan di seluruh dunia kembali menegaskan pentingnya desain keselamatan kebakaran terowongan, deteksi dini, dan pemadaman kebakaran awal. Konsekuensi parah dari kebakaran terowongan dapat berupa evakuasi yang sulit dari ruang berventilasi buruk dengan asap bersuhu tinggi dan kepadatan tinggi serta gas beracun. Lebih lanjut, setelah kebakaran terowongan terjadi, untuk mendorong evakuasi yang aman, pemadaman awal merupakan hal terpenting karena perkembangan api yang cepat dan waktu pemulihan yang terbatas.

Selain optimalisasi desain keselamatan kebakaran terowongan dan deteksi dini serta pemberian alarm kebakaran, penting juga untuk mengidentifikasi skenario kebakaran secara real-time serta memprediksi evolusi kebakaran berdasarkan zat beracun dan perambatan api dalam berbagai skenario dengan menggunakan detektor kebakaran, sensor, dan metode lain yang lebih canggih, seperti jaringan sensor *Internet of Things* (IoT) dan metode kecerdasan buatan (AI). Seperti halnya pada kebakaran gedung, sebagian besar korban kebakaran terowongan disebabkan oleh menghirup asap. Dalam kebakaran terowongan, panas, asap panas, dan gas beracun dari hasil pembakaran akan menyebar di sepanjang terowongan dan menimbulkan dampak yang mengancam jiwa bagi penghuni di dalamnya. Api di terowongan cenderung membakar dengan hebat di ruang tertutup karena adanya umpan balik panas dari lapisan terowongan, sementara barang-barang kimia yang dibawa oleh truk besar menambah kemungkinan terjadinya ledakan.

Oleh karena itu, merancang sistem ventilasi yang andal menjadi salah satu fitur keselamatan terpenting dalam perencanaan terowongan. Proteksi kebakaran di terowongan secara fundamental berbeda dengan proteksi kebakaran pada bangunan konvensional, di mana kompartemen api dan asap menjadi prioritas serta sistem proteksi aktif seperti sprinkler atau kabut air diwajibkan atau direkomendasikan. Penerapan prinsip kompartemen dalam lingkungan terowongan justru akan mengurangi kapasitas evakuasi. Prinsip utama dalam proteksi kebakaran terowongan adalah mengendalikan penyebaran asap, sehingga sebagian besar peraturan mengharuskan sistem ventilasi asap yang mampu memastikan tersedianya waktu evakuasi yang aman (ASET).

Sistem ventilasi dapat bersifat alami maupun mekanis. Berdasarkan metode dan konfigurasi ekstraksi asap, sistem dapat berupa semi-transversal, sepenuhnya melintang, ekstraksi samping, ekstraksi vertikal, atau kombinasi lainnya. Kipas jet tambahan di langit-langit juga sering dipasang untuk membantu mengendalikan aliran longitudinal. Setiap sistem memiliki kelebihan dan kekurangan dari segi kinerja, biaya, dan keandalan. Dalam praktiknya, desain proteksi kebakaran terowongan umumnya berbasis kinerja, sehingga diperlukan pemeriksaan dan optimasi menyeluruh dengan bantuan simulasi numerik terkait proses kebakaran dan evakuasi.

Sistem evakuasi terowongan biasanya mencakup beberapa rute pelarian yang ditempatkan pada interval tertentu atau berupa stasiun penyelamatan. Rute ini dapat berupa jalan pintas antara dua tabung terowongan paralel atau tempat perlindungan khusus yang dirancang untuk pengungsi. Jarak pemisah dan kapasitas jalan keluar sangat bergantung pada peraturan, kode, standar, maupun pedoman yang berlaku di setiap lokasi. Penghuni harus

segera mengungsi atau mencari tempat berlindung pada tahap awal kebakaran sebelum kondisi semakin memburuk. Namun, evakuasi sering terhambat oleh kesulitan menemukan pintu keluar dan jalur yang tepat di lingkungan gelap, terutama karena penghuni tidak terbiasa dengan tata letak terowongan dan jarang berada di dalamnya dalam kehidupan sehari-hari.

Untuk mengatasi hal tersebut, analisis rekayasa berbasis kinerja diperlukan guna mensimulasikan skenario kebakaran dan pergerakan asap yang kemudian digunakan untuk membantu pemodelan evakuasi. Secara keseluruhan, evakuasi dalam kebakaran terowongan masih merupakan bidang penelitian yang relatif baru, terutama karena masih terbatasnya pemahaman tentang perilaku manusia di lingkungan kebakaran terowongan.


18.2 DINAMIKA DAN DATA KEBAKARAN TEROWONGAN

Gambar 18.2 memperlihatkan (a) diagram kebakaran terowongan beserta parameter utama lapisan api dan asap, serta (b) strategi ventilasi umum, seperti ekstraksi asap memanjang (longitudinal) dan melintang (transversal). Dibandingkan dengan kebakaran pada bangunan yang telah diteliti hampir satu abad, penelitian tentang kebakaran terowongan masih tergolong baru karena baru dimulai pada akhir 1950-an. Jumlah uji coba kebakaran terowongan berskala penuh juga masih terbatas karena pelaksanaannya berbahaya dan sulit menjamin keselamatan peneliti.

Dalam keselamatan kebakaran terowongan, terdapat dua pertanyaan utama dalam penelitian dan desain, yaitu: (1) bagaimana memahami dinamika kebakaran serta peristiwa kritis terkait evolusi api dan asap di ruang terowongan tertutup, dan (2) bagaimana merancang Sistem Pemadam Kebakaran Tetap (*Fixed Fire Fighting System/FFFS*), khususnya sistem ventilasi, yang dapat menjamin keselamatan pengungsi. Untuk mempelajari dinamika kebakaran terowongan, digunakan tiga metode utama, yaitu: (1) uji kebakaran berskala penuh di terowongan nyata, (2) eksperimen di laboratorium dengan model terowongan berskala lebih kecil, dan (3) simulasi numerik berbasis dinamika fluida komputasional (*Computational Fluid Dynamics/CFD*).

Hasil uji coba kebakaran terowongan skala penuh dianggap paling andal dan bernilai tinggi karena dapat digunakan untuk memverifikasi hasil uji skala laboratorium maupun sebagai acuan dalam perancangan sistem keselamatan kebakaran terowongan. Beberapa uji coba penting telah dilakukan di berbagai negara, namun jumlahnya masih sedikit. Hal ini disebabkan karena uji coba berskala nyata memerlukan biaya yang sangat besar sekaligus memiliki risiko keselamatan yang tinggi.

Sebagai perbandingan, uji laboratorium menggunakan model skala kecil memberikan data eksperimen yang lebih banyak dengan biaya dan risiko yang lebih rendah. Melalui pendekatan hukum skala (*scale law*), peneliti dapat menganalisis hubungan antara laju pelepasan panas api (*Heat Release Rate/HRR*), ukuran api, suhu dan kecepatan asap, serta dimensi terowongan. Dari analisis tersebut, diperoleh korelasi empiris dan hukum skala baru yang disesuaikan dari penelitian kebakaran pada bangunan.



Gambar 18.2: Diagram (a) pergerakan api dan asap terowongan yang umum, dan (b) sistem ventilasi asap di dalam terowongan.

Dinamika api dan asap dalam terowongan sebagian besar dikendalikan oleh gaya apung. Karena itu, analisis klasik berbasis bilangan Zukoski dan bilangan Froude (parameter tak berdimensi yang digunakan untuk menggambarkan aliran fluida) masih berlaku. Namun, uji coba kebakaran terowongan skala kecil maupun analisis berbasis hukum skala lebih sesuai untuk memahami kondisi tunak. Untuk proses yang bersifat transien, seperti pemadaman dan evakuasi kebakaran, model berskala kecil kurang tepat karena faktor waktu tidak terwakili dalam pemodelan.

Kemajuan teknologi komputasi dalam beberapa tahun terakhir telah mendorong penggunaan simulasi berbasis dinamika fluida komputasional (*Computational Fluid Dynamics/CFD*) secara lebih luas dalam penelitian kebakaran terowongan dan perancangan sistem keselamatan. Simulasi numerik ini mampu memberikan informasi detail yang sulit diperoleh dari eksperimen, misalnya distribusi suhu, aliran asap, atau perambatan api. Beberapa perangkat lunak CFD yang banyak digunakan antara lain *Fire Dynamics Simulator* (FDS) dan ANSYS Fluent. Saat ini, kombinasi antara eksperimen (baik skala penuh maupun skala model) dengan simulasi numerik menjadi pendekatan umum, baik untuk penelitian maupun desain keselamatan berbasis kinerja pada kebakaran terowongan.

Walaupun sudah tersedia sejumlah standar dan panduan internasional, seperti NFPA 130 dan NFPA 502, masih banyak aspek kebakaran terowongan yang membutuhkan penelitian lebih lanjut. Beberapa di antaranya adalah sistem deteksi dini, mekanisme evakuasi darurat, serta metode prediksi perilaku api dan asap di dalam terowongan. Setelah kebakaran terjadi, informasi langsung di lokasi seperti titik awal kebakaran, ukuran api, serta jumlah dan posisi orang di dalam terowongan sangat penting untuk pengambilan keputusan dalam pemadaman dan tanggap darurat. Berbagai teknologi deteksi kebakaran telah digunakan, misalnya detektor panas tipe garis atau kamera termal. Namun, teknologi ini umumnya hanya mampu mendeteksi titik api, bukan memantau perkembangan kebakaran dan pergerakan asap secara real-time. Akibatnya, sistem tersebut bisa menjadi kurang efektif ketika api berkembang cepat atau arah asap berubah. Karena itu, penelitian saat ini mulai berfokus pada pengembangan

sistem deteksi dan pemantauan cerdas berbasis teknologi real-time, yang mampu sekaligus mendeteksi, melacak, dan memprediksi dinamika kebakaran di dalam terowongan.

Kejadian Kebakaran Kritis di Terowongan

Pada bagian ini, dibahas parameter-parameter utama dalam kebakaran terowongan dan kejadian kritis yang terkait, meliputi laju pelepasan panas kebakaran (Heat Release Rate/HRR), panjang nyala api, suhu maksimum di langit-langit, ketebalan lapisan asap, kecepatan ventilasi kritis, panjang aliran balik asap, serta fenomena *plug-holing* (gangguan aliran akibat terbentuknya pusaran asap). Berbeda dengan kebakaran kompartemen bangunan konvensional, kebakaran terowongan umumnya tidak mengalami fenomena *flashover* (penyalan hampir serentak seluruh bahan bakar dalam suatu ruang).

Hal ini terjadi karena mustahil menyalakan seluruh bahan bakar, seperti kendaraan yang berjajar di sepanjang terowongan. Selain itu, perilaku kebakaran terowongan juga berbeda dengan kebakaran di ruang terbuka, karena pasokan oksigen di dalam terowongan jauh lebih terbatas. Akibatnya, dinamika asap menjadi aspek utama yang memengaruhi perkembangan kebakaran. Dengan alasan serupa, meskipun kerusakan lokal pada struktur seperti spalling (pengelupasan) beton atau deformasi bajamdaat terjadi, keruntuhan total terowongan akibat kebakaran sangat jarang. Oleh karena itu, ketahanan api struktur terowongan tidak dibahas lebih lanjut di sini.


Salah satu parameter paling penting adalah HRR, yang menggambarkan ukuran dan tingkat keparahan kebakaran. HRR memiliki keterkaitan langsung dengan parameter lain, seperti panjang nyala api dan kecepatan ventilasi kritis. Karena bahan bakar utama di dalam terowongan adalah kendaraan dan barang bawaan, uji coba skala penuh biasanya menggunakan kendaraan nyata sebagai sumber api, atau disimulasikan dengan pembakar gas maupun api berbahan bakar cair.

Laju pelepasan panas puncak (peak HRR/pHRR) suatu kendaraan sangat bergantung pada jenis kendaraan dan kondisi ventilasi. Secara umum, pHRR berkisar antara 1–5 MW untuk mobil penumpang kecil, 1–10 MW untuk mobil penumpang besar, 10–50 MW untuk bus atau kendaraan barang berat, dan dapat mencapai 300–430 MW untuk kapal tanker minyak. Karena pembakaran kendaraan nyata di dalam terowongan sulit dilakukan, peneliti sering kali menggunakan pembakar bahan bakar gas atau cair yang lebih mudah dikendalikan untuk meniru karakteristik api kendaraan.

Panjang nyala api digunakan untuk menggambarkan ukuran karakteristik api. Dalam konteks kebakaran terowongan, tinggi nyala api (L_f) merupakan parameter yang paling sering dianalisis. Nyala api yang mencapai langit-langit dapat menimbulkan fenomena api merambat (*flame extension*), yang berdampak besar pada penyebaran api maupun kerusakan struktur. Panjang nyala api berkorelasi dengan ukuran pembakar, dan salah satu rumus yang banyak digunakan adalah:

$$\frac{L_f}{D} = 1,7$$

dengan L_f adalah tinggi nyala api dan D adalah diameter sumber api. Parameter penting lainnya adalah suhu gas maksimum di langit-langit terowongan. Nilai ini dapat digunakan untuk menentukan ambang batas sistem deteksi panas dan asap, serta untuk memperkirakan ketahanan struktur terhadap paparan api dalam jangka waktu tertentu. Banyak faktor, seperti percabangan struktur, penyegelan portal, dan penyumbatan, akan memengaruhi pergerakan asap dan suhu maksimum dalam berbagai kondisi ventilasi. Serupa dengan suhu jet langit-langit di dalam ruangan, rumus empiris sering digunakan untuk menghitung suhu gas maksimum $\Delta T_{max} = \alpha Q^{2/3} / H_{ef}^{5/3}$ dimana koefisien α biasanya sekitar 16,9–17,9.



Gambar 18.3: Diagram (a) fenomena back-layering ketika ventilasi longitudinal berada di bawah kecepatan kritis, dan (b) fenomena plug-holing pada sistem ventilasi asap vertikal di terowongan.

Back-layering secara umum didefinisikan sebagai fenomena di mana asap mengalir ke arah ventilasi meskipun kipas angin beroperasi, yang berdampak negatif pada pengungsi. Seperti ditunjukkan pada Gambar 18.3(a), panjang *back-layering* (L_b) dapat didefinisikan sebagai panjang antara tepi depan asap dan sumber api yang berlawanan dengan arah angin ventilasi. Kecepatan kritis ventilasi asap (V_c) didefinisikan sebagai kecepatan ventilasi longitudinal minimum yang mencegah pergerakan produk pembakaran ke hulu dari api. Thomas pertama kali mengusulkan konsep back-layering dan memodifikasi bilangan Froude untuk mempertimbangkan pengaruh hambatan gesek pada jarak back-layering asap.

Berdasarkan banyak eksperimen terbaru, berbagai persamaan diusulkan untuk menghitung jarak back-layering tanpa dimensi dan kecepatan kritis. Fenomena plug-holing terjadi di Sistem Ventilasi Alami (NVS) terowongan. Ketika lapisan udara segar bagian bawah bercampur dengan lapisan asap bagian atas, fenomena plug-holing terjadi di dekat wilayah poros, seperti yang ditunjukkan pada Gambar 18.3(b). Studi yang menyelidiki fenomena ini sangat terbatas, dan sebagian besar studi yang ada menggunakan analisis teoretis atau model skala tereduksi.

Pembentukan Basis Data Kebakaran Terowongan

Basis data pelatihan yang besar dan andal sangat penting untuk melatih model AI dan memungkinkannya mempelajari fitur tersembunyi dari fenomena kebakaran, sehingga kuantitas dan keragaman basis data harus cukup besar (Gambar 18.4). Basis data kebakaran terowongan dapat dibangun berdasarkan data sensor dari uji/peristiwa kebakaran sebelumnya dan simulasi numerik. Dalam praktiknya, baik data sensor maupun data numerik tidak sempurna, dan semuanya memiliki kelebihan dan kekurangan.

Data sensor: Untuk uji kebakaran umum atau kejadian kebakaran nyata, beberapa parameter umumnya diukur oleh sensor titik terdistribusi, seperti suhu oleh termokopel atau detektor panas lainnya, keberadaan asap demi asap oleh detektor, CO dan CO₂ oleh detektor gas, dan fluks panas oleh radiometer. Sensor titik sering dipasang di satu atau beberapa lokasi untuk pengukuran jangka panjang. Sensor pencitraan juga umum dipasang di dalam terowongan, termasuk kamera sirkuit tertutup (CCTV), detektor api, dan kamera inframerah.

Sayangnya, basis data sensor untuk kebakaran terowongan sangat terbatas. Ada dua alasan utama. Pertama, meskipun banyak penelitian telah mempublikasikan uji kebakaran terowongan mereka ke jurnal dan laporan teknis, sebagian besar data mentah tidak dapat diakses secara terbuka atau sulit diekstraksi dari plot. Pada dasarnya, sebagian besar data uji kebakaran yang ada awalnya tidak diproduksi dan disajikan berdasarkan prinsip berbagi; dan sebagian besar penelitian hanya tertarik untuk menghasilkan korelasi empiris untuk kondisi tunak, sehingga sebagian besar data transien diabaikan atau kurang terdokumentasi. Dalam hal data video, sebagian besar tidak tersedia daring, dan bahkan jika para peneliti ingin berbagi, berkas video tersebut seringkali terlalu besar untuk dibagikan dengan mudah. Lebih penting lagi, seluruh komunitas penelitian kebakaran belum menyadari nilai dan pentingnya data.

Kedua, untuk terowongan yang ada, data sensor juga tidak tersedia untuk membentuk basis data. Di satu sisi, kejadian kebakaran dianggap sebagai peristiwa langka, sehingga sebagian besar data operasional harian tidak terkait dengan kebakaran. Di sisi lain, sebagian besar sensor, seperti detektor panas dan detektor asap, tidak merekam, menyimpan, atau membagikan data, karena sistemnya tidak dirancang untuk melakukannya. Begitu kebakaran terjadi, sebagian besar sensor dan kabel utama di dekat lokasi kebakaran dapat rusak. Oleh karena itu, sistem pengumpulan data baru diperlukan untuk mendukung pemadaman kebakaran cerdas di terowongan (lihat Bagian 3.1).

Basis data kebakaran numerik: Dibandingkan dengan melakukan eksperimen kebakaran terowongan, simulasi komputasional (atau eksperimen numerik) untuk kebakaran terowongan lebih hemat biaya. Selain itu, hasil pemodelan CFD dapat memberikan informasi suhu yang jauh lebih detail daripada eksperimen apa pun. Saat ini, simulasi CFD telah banyak digunakan dalam penelitian kebakaran, analisis teknik, atau desain berbasis kinerja infrastruktur kompleks, seperti atrium, ruang bawah tanah, dan terowongan. Basis data yang dibentuk oleh simulasi numerik berbasis CFD yang masif dapat memungkinkan prakiraan kebakaran berbasis AI.

Untuk simulasi numerik, data visual mengacu pada kontur dan video yang dihasilkan dari hasil komputasi. Data urutan waktu ini (misalnya, gambar dan video) dapat secara langsung menunjukkan lokasi dan skala kebakaran secara langsung, proses evakuasi, distribusi asap dan suhu, serta aktivitas pemadaman kebakaran. Dibandingkan dengan data sensor dalam uji kebakaran, data numerik 2D atau 3D beberapa kali lipat lebih besar, yang dapat menunjukkan lebih banyak detail tentang proses kebakaran.

Sebaliknya, data video dalam uji kebakaran dan terowongan nyata cukup langka dan sebagian besar tidak dipublikasikan. Meskipun terdapat video uji api, video tersebut kurang seragam karena sudut pengambilan gambar yang beragam, dan ukuran serta kompleksitasnya yang besar menghambat pemrosesan data dan analisis ilmiah lebih lanjut. Meskipun telah ada ribuan simulasi kebakaran terowongan yang dilakukan oleh para peneliti dan insinyur, sangat sedikit yang tersedia untuk diakses dan digabungkan menjadi basis data yang besar. Masalah yang sama dengan basis data eksperimental adalah komunitas belum menyadari pentingnya data numerik, dan tidak ada pedoman untuk menyimpan, mengelola, dan membagikan data tersebut.

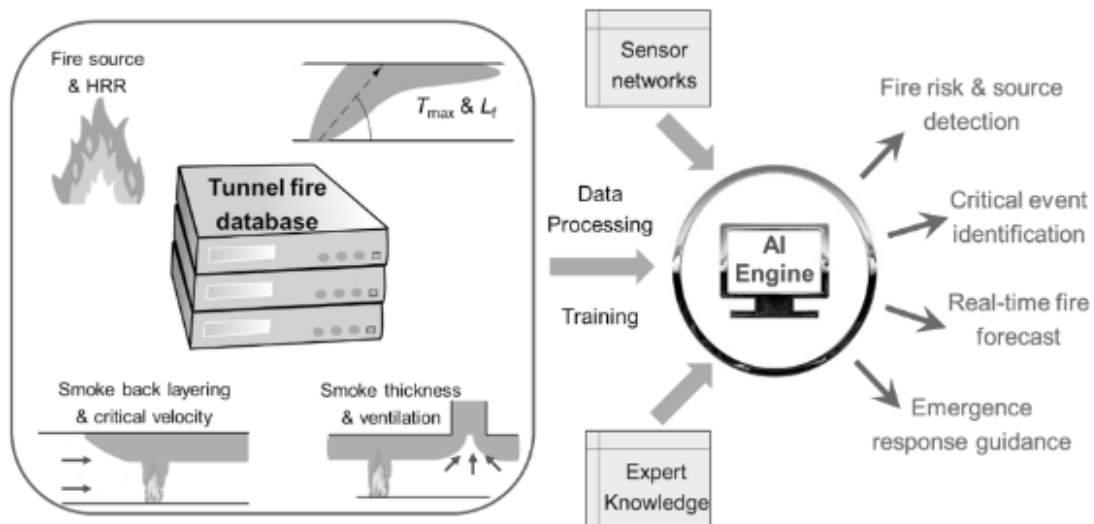
Idealnya, data sensor yang memadai dapat diperoleh dari eksperimen kebakaran skala penuh atau insiden kebakaran nyata, dan semua data simulasi kebakaran numerik sebelumnya disimpan dalam basis data cloud terbuka yang besar. Namun, data kebakaran terowongan yang ada dari literatur tidak cukup besar atau terorganisasi dengan baik untuk mendukung pelatihan AI, khususnya pelatihan data multidimensi (misalnya, gambar dan video) dari algoritma pembelajaran mendalam. Terlepas dari berbagai tantangan, basis data kebakaran global harus dibangun selangkah demi selangkah. Selain itu, sangat mendesak untuk menetapkan standar dan pedoman global untuk mengorganisasikan, menyajikan, dan berbagi data penelitian kebakaran sebagai upaya komunitas.

Tantangan dan perspektif: Singkatnya, ada empat perubahan dalam membentuk basis data untuk kebakaran terowongan atau jenis kebakaran lainnya.

- (1) Data eksperimen dan numerik yang tidak memadai dicatat, dilaporkan, dan dianalisis dalam literatur, terutama data transien (yaitu, data berubah seiring waktu).
- (2) Ukuran data sangat besar, tidak hanya mencakup data transien dari puluhan atau ratusan sensor, tetapi juga video dan hasil CFD yang dapat dengan mudah mencapai ukuran 100 GB atau 1 TB.
- (3) Para peneliti tidak memiliki kemampuan analisis untuk menangani data dalam jumlah besar tersebut. Sebagian besar korelasi empiris berbasis fisika dan metode analisis konvensional hanya dapat menginterpretasikan kondisi kebakaran steady-state. Diperlukan pendekatan analisis data baru (misalnya, metode berbasis data).
- (4) Komunitas juga kurang memiliki kebiasaan dan standar dalam mencatat, mengorganisir, dan berbagi data, karena membutuhkan waktu tambahan tanpa hasil langsung, dan sebagian besar peneliti belum menyadari pentingnya data.

Saat ini, data literatur kebakaran terowongan hanya dapat dikategorikan berdasarkan parameter kunci dalam kebakaran terowongan, seperti ukuran api, ketebalan lapisan asap, kecepatan kritis, panjang lapisan belakang, dan plug-holing, melalui tinjauan literatur yang

menyeluruh. Meskipun data eksperimental dan numerik yang lebih banyak dapat diekstraksi dari dokumen yang dipublikasikan atau diminta dari beberapa penulis, sulit untuk menata ulang semuanya oleh sekelompok kecil peneliti.



Gambar 18.4: Proses pembangunan basis data eksperimental dan numerik untuk pemadaman kebakaran terowongan pintar.

Sebagai perbandingan, melakukan simulasi kebakaran terowongan baru merupakan cara termudah untuk membentuk basis data yang dapat digunakan untuk mendemonstrasikan pelatihan dan penerapan model AI. Jika model numerik divalidasi melalui beberapa uji kebakaran terowongan skala penuh, keandalan basis data numerik akan meningkat secara signifikan. Karena basis data harus cukup besar untuk mencakup berbagai skenario kebakaran, parameter kunci harus divariasikan dalam eksperimen dan simulasi numerik.

Tabel 18.2 mencantumkan sekelompok parameter yang dapat divariasikan untuk membentuk basis data kebakaran terowongan. Misalnya, jika 10 panjang terowongan, 10 HRR kebakaran, 10 lokasi kebakaran, dan 10 kecepatan ventilasi dipertimbangkan, basis data akan mencakup 104 skenario kebakaran. Jika basis data terlalu besar, akan memakan waktu untuk membentuk dan melatihnya. Oleh karena itu, penting untuk memilih parameter kunci dan rentang variasi yang sesuai untuk membentuk basis data yang memadai.

Untuk memudahkan pencarian dalam basis data besar, semua data mentah harus diberi nama, terorganisir, dan diindeks dengan baik beserta deskripsi yang detail. Karena proses pembakaran umumnya kompleks dan dipengaruhi oleh banyak faktor, penting untuk menyediakan informasi masukan dan kondisi batas yang memadai sebelum pemrosesan data. Setelah data terkumpul, pembentukan basis data merupakan tugas multi-langkah: (1) pengumpulan data dengan menelusuri semua literatur yang tersedia dan mengekstrak semua data yang berguna dari dokumen-dokumen tersebut, (2) pra-pemrosesan data dengan pemeriksaan kualitas data, penghapusan outlier dan noise, serta penyaringan, dan (3) penggalian data dengan mengekstrak informasi berharga.

Tabel 18.2: Parameter utama kebakaran terowongan.

Jenis	Parameter	Keterangan
Terowongan	Panjang	0.1 – 100 km
	Geometri dan ukuran penampang	
	Kemiringan	< 3°
Kebakaran	Ukuran api atau laju pelepasan panas	2 – 100 MW
	Lokasi awal kebakaran	
	Laju pertumbuhan dan penurunan api	
	Kecepatan penyebaran api	0 – 2 m/menit
Sistem Proteksi Kebakaran atau Lingkungan	Metode ventilasi, desain, dan kapasitas	Longitudinal, transversal, dll
	Distribusi pintu evakuasi dan rute darurat	
	Angin dan ketinggian	

18.3 PREDIKSI KEBAKARAN TEROWONGAN OLEH IOT DAN AI

Jaringan Sensor Internet of Things (IoT) dan Kembaran Digital Multi-Fisik

Konsep Kembaran Digital digagas pada awal tahun 2000-an dan bisa dibilang pertama kali diadopsi oleh NASA dalam upaya meningkatkan simulasi model fisik pesawat ruang angkasa pada tahun 2010. Saat ini, kembaran digital telah diterapkan pada mesin pesawat, proses manufaktur (Tao dkk., 2019), dan infrastruktur besar seperti gedung pintar dan turbin angin, tetapi teknologinya secara keseluruhan masih jauh dari matang (Tao dkk., 2019).

Beberapa gedung yang sudah ada memiliki sistem manajemen gedung (BMS) atau sistem otomasi gedung (BAS). BMS adalah sistem kontrol berbasis komputer yang terpasang di dalam gedung yang mengontrol dan memantau HVAC (Pemanas, ventilasi, dan pendingin udara), pencahayaan, sistem kelistrikan, sistem kebakaran, dan sistem keamanan gedung (Wang, 2009). Sebagian besar sistem ini hanya dipasang di gedung-gedung baru dan gedung-gedung bersejarah, karena biayanya yang tinggi dan kurangnya persyaratan wajib. Sebagian besar sistem BMS saat ini tidak terhubung satu sama lain karena penggunaan protokol internet yang berbeda oleh berbagai produsen. Misalnya, sistem HVAC tidak terhubung dengan sistem kebakaran, dan datanya tidak dibagikan satu sama lain, meskipun dibuat oleh perusahaan yang sama.

Baru-baru ini, Digital Twin bangunan diusulkan untuk dibangun berdasarkan Building Information Model (BIM) pada tahap desain gedung baru dan mencakup semua sensor dan informasi kamera dari sistem IoT. Namun demikian, perangkat lunak BIM saat ini pada dasarnya merupakan alat desain yang tidak memiliki kapasitas untuk transfer dan manajemen data secara real-time. Pendekatan dan standar baru diperlukan untuk mengintegrasikan jaringan sensor IoT ke dalam perangkat lunak BMS atau BIM. Secara optimis, sistem layanan kebakaran yang ada memiliki satu keunggulan besar dibandingkan sistem bangunan lainnya. Yaitu, sebagian besar sensor (detektor asap, panas, dan api) terhubung ke panel kontrol pusat.

Dengan demikian, data informasi kebakaran tentang suhu langit-langit dan kepadatan asap dapat langsung direkam dan diproses dengan meningkatkan sistem yang dapat dialamatkan saat ini. Sistem kebakaran yang dapat dialamatkan saat ini hanya mengeluarkan alarm kebakaran, tetapi tidak merekam dan memberikan informasi tambahan tentang lokasi kebakaran. Pada akhirnya, data suhu dan laju aliran yang diukur oleh sensor HVAC, serta rekaman kamera CCTV, juga dapat dibagikan dengan sistem kebakaran, meskipun diperlukan penelitian, pengembangan, dan implikasi selama bertahun-tahun.


Digital Twin kebakaran yang diusulkan dapat diperbarui secara berkala berdasarkan informasi risiko kebakaran, seperti beban bahan bakar di setiap zona kebakaran dan pengangkutan material berbahaya kebakaran tinggi di dalam gedung. Setelah kebakaran terjadi, meskipun asap tebal dari kebakaran juga dengan cepat mengurangi informasi visual, jaringan sensor IoT suhu dan asap dapat terus merekam dan menganalisis data lokasi kebakaran sebelum petugas pemadam kebakaran tiba. Informasi penting kebakaran, seperti lokasi dan laju pelepasan panas (atau daya) sumber api serta progres evakuasi penghuni, dapat diidentifikasi oleh mesin AI untuk mendukung respons darurat dan kegiatan pemadaman kebakaran.

Hal ini mengharuskan Digital Twin kebakaran digabungkan dengan basis data kebakaran yang telah ditetapkan sebelumnya yang digunakan untuk melatih mesin AI. Basis data kebakaran tersebut mencakup ribuan simulasi kebakaran berbasis CFD, data eksperimen, dan korelasi empiris dari bangunan tertentu. Dengan informasi waktu nyata (real-time), seperti data dari sensor suhu dan kamera, mesin AI yang telah dilatih sebelumnya dapat dengan cepat mengenali, memvisualisasikan, dan merender lokasi kebakaran pada Digital Twin.

Terakhir, untuk meningkatkan keselamatan kebakaran bangunan secara keseluruhan, perlu dipasang semua sensor terkait keselamatan kebakaran dan terhubung dengan sensor dan sistem bangunan lainnya untuk membentuk kembaran digital bangunan pintar. Gambar 18.5 menunjukkan diagram Kembaran Digital Kebakaran Pintar (SFDT) yang diusulkan untuk kebakaran terowongan. SFDT memiliki empat komponen utama:

- (1) Jaringan sensor, yang dipasang di terowongan sebelum insiden kebakaran untuk mengumpulkan data suhu di lokasi.
- (2) Komponen server data cloud, yang membaca data yang ditransfer dari jarak jauh dari jaringan sensor ke server dan menyimpan data dalam format standar.
- (3) Komponen mesin AI, yang memanfaatkan data terukur yang tersedia untuk memberikan identifikasi, prakiraan, dan peringatan dini tentang potensi skenario kebakaran kepada petugas pemadam kebakaran secara real-time.
- (4) Antarmuka pengguna, yang dapat mengambil keluaran mesin AI untuk menampilkan lokasi kebakaran ke pusat operasi dan memberi peringatan kepada petugas pemadam kebakaran dan komandan dalam mode ramah.

Di antara komponen-komponen ini, mesin AI yang memungkinkan kembaran digital untuk bertindak otomatis dan cerdas dalam menangani insiden kebakaran terowongan memainkan peran sentral. Panah dalam diagram menunjukkan arah aliran data dan interaksi antara setiap komponen.



Gambar 18.5: Kembaran digital api pintar untuk terowongan yang dapat memantau perilaku kebakaran secara real-time, memprakirakan evolusi kebakaran oleh AI, dan mendukung operasi pemadaman kebakaran cerdas.

Metode AI untuk Mengidentifikasi dan Memprediksi Kebakaran Terowongan

Konsep kecerdasan buatan (Artificial Intelligence/AI) pertama kali diperkenalkan dalam sebuah lokakarya di Dartmouth College pada tahun 1956, dengan fokus pada permasalahan komputasi seperti pemahaman bahasa, penyimpanan data, dan pencocokan pola. Sejak saat itu, perkembangan AI bersama teknologi mutakhir lainnya, seperti pemantauan jarak jauh, sensor beresolusi tinggi, komputasi berkecepatan tinggi, serta metode berbasis data, semakin banyak dimanfaatkan dalam rekayasa keselamatan kebakaran.

Sejumlah penelitian telah mengeksplorasi pemanfaatan AI untuk kebakaran kompartemen maupun kebakaran terowongan. Sebagian besar penelitian tersebut menggunakan jaringan saraf tiruan (JST/Artificial Neural Network) untuk melatih basis data dari uji kebakaran dan simulasi kebakaran numerik, baik berupa data suhu maupun citra asap. Hasil pelatihan ini digunakan untuk mengidentifikasi laju pelepasan panas kebakaran (Heat Release Rate/HRR), menetapkan kriteria desain rekayasa kebakaran, serta memperkirakan kemungkinan terjadinya *flashover* (penyalan mendadak hampir semua material mudah terbakar dalam suatu ruang). Selain itu, berbagai algoritma pembelajaran mesin (machine learning) telah dikembangkan untuk melatih basis data dan membangun hubungan kompleks antara data sensor dengan dinamika kebakaran, sehingga memungkinkan pembuatan prakiraan kebakaran secara real-time.

Studi terbaru juga menunjukkan bahwa AI dapat diterapkan untuk mengidentifikasi skenario kebakaran secara real-time, memperkirakan kejadian kebakaran kritis, serta memantau dan memvisualisasikan lokasi kebakaran dua dimensi secara langsung. Pendekatan ini mendukung terwujudnya sistem pemadaman kebakaran cerdas, khususnya pada lingkungan kompleks seperti terowongan.

Salah satu metode yang banyak digunakan adalah jaringan saraf rekuren (Recurrent Neural Network/RNN), yang dirancang khusus untuk menganalisis data temporal atau berseri waktu. RNN memiliki struktur berulang yang dapat diurai menjadi rantai sel, sehingga setiap data berurutan dapat diproses dan informasi yang terkandung di dalamnya dapat dipelajari untuk menghasilkan keluaran. Pengembangan lebih lanjut dari RNN adalah *Long Short-Term Memory* (LSTM), yaitu model dengan struktur internal khusus yang mampu mengatasi permasalahan prediksi kompleks, misalnya pada pengenalan suara. Sel LSTM bekerja dengan tiga komponen utama yang disebut *gerbang* (gate), yang berfungsi untuk mengatur aliran informasi yang disimpan, diperbarui, dan diteruskan.

Ketika data diimpor ke dalam sel, gerbang lupa, gerbang masukan, dan gerbang keluaran bersama-sama memutuskan apakah akan memblokir atau meneruskannya, bagaimana menanganinya, dan bagaimana mengeluarkannya. Kemudian, setelah mengimpor suatu data, hanya informasi berguna yang akan diingat, diterjemahkan, dan diakumulasikan untuk keluaran yang dirancang. Salah satu kelompok aplikasi AI dalam kebakaran adalah untuk mengidentifikasi informasi skenario kebakaran dan memperkirakan kejadian kebakaran kritis di masa mendatang, dan unit LSTM paling efektif untuk menangani masalah ini.

Dengan basis data numerik yang dihasilkan pada Gambar 18.6(b), unit LSTM di lapisan input menerima vektor suhu yang diukur oleh sensor secara berurutan. Data yang diterima kemudian diolah dan diteruskan ke status berikutnya. Dengan demikian, vektor multi-elemen (misalnya, lokasi kebakaran, HRR, dan kecepatan ventilasi) dapat diprediksi secara akurat. Untuk memverifikasi akurasi deteksi kebakaran berbasis AI, analisis sensitivitas perlu dilakukan untuk mengoptimalkan konfigurasi basis data dan pengaturan spasial-temporal sensor.

Kelompok aplikasi AI lainnya dalam pemadaman kebakaran cerdas adalah untuk memperkirakan dan menampilkan lokasi/gambar kebakaran di masa mendatang dalam antarmuka pengguna untuk mendukung pengambilan keputusan oleh komandan pemadam kebakaran dan operasi pemadaman kebakaran di lapangan. Untuk melatih data citra masif, algoritma jaringan saraf tiruan konvensional (CNN) harus digunakan, yang telah banyak diterapkan di berbagai bidang terkait visi komputer, seperti pengenalan dan klasifikasi citra. Secara teknis, serangkaian lapisan konvolusional dan penggabungan didefinisikan dalam model CNN untuk melewati citra masukan yang memiliki volume lebih besar untuk mengeluarkan data yang diinginkan dengan ukuran lebih kecil.

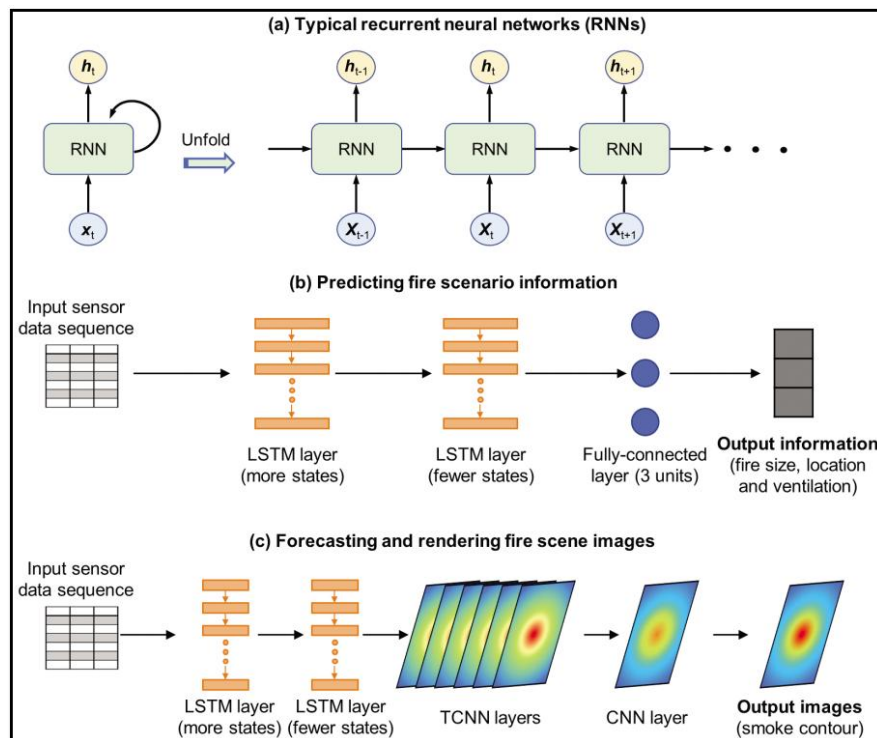
Sebagai dekoder berbasis Convolutional Neural Network (CNN), Temporal CNN (TCNN) bekerja dengan cara berlawanan dibandingkan encoder, yaitu mengubah data masukan sederhana menjadi representasi dengan dimensi lebih tinggi. Berdasarkan hal tersebut, dikembangkan sebuah model pembelajaran mendalam yang menggabungkan Long Short-Term Memory (LSTM) dengan TCNN. Model ini terdiri atas lapisan LSTM, lapisan padat (dense layer), dan TCNN.

Model gabungan ini diharapkan mampu menghasilkan citra yang menunjukkan distribusi suhu, visibilitas asap, dan konsentrasi gas di dalam terowongan. Lebih jauh, dari hasil prakiraan citra lokasi kebakaran, informasi penting seperti ketebalan dan panjang lapisan asap dapat diperkirakan melalui proses pasca-pemrosesan. Ke depan, algoritma AI tersebut dapat

disesuaikan dan dioptimalkan untuk menangani permasalahan rekayasa kebakaran yang lebih spesifik dengan antarmuka yang ramah pengguna. Pada tahap ideal, setiap insinyur maupun peneliti kebakaran akan mampu menggunakan kode-kode AI ini untuk mensimulasikan skenario kebakaran kompleks secara cepat serta mengekstraksi informasi mendalam dari basis data berskala besar, serupa dengan pemodelan kebakaran menggunakan Computational Fluid Dynamics (CFD).

Saat ini, CFD umumnya digunakan oleh komunitas peneliti kebakaran, bukan oleh ahli matematika atau ilmuwan komputer yang mengembangkan pemecah persamaan diferensial maupun perangkat lunak CFD. Dengan pola serupa, AI juga diperkirakan akan menjadi alat penting dalam aplikasi dan penelitian rekayasa kebakaran di masa depan. Mesin prakiraan kebakaran berbasis AI yang matang bahkan diharapkan dapat diimplementasikan di setiap bangunan untuk mendeteksi dan memprediksi lokasi kebakaran serta mendukung sistem pemadaman kebakaran cerdas.

Meski demikian, pengembangan AI untuk kebutuhan komunitas kebakaran memerlukan kolaborasi multidisiplin antara ilmuwan komputer, komunitas teknologi informasi, petugas pemadam kebakaran, regulator, dan pembuat kebijakan. Bagi para insinyur dan peneliti kebakaran, pemahaman mendasar mengenai algoritma AI sangat dianjurkan. Pengetahuan tersebut penting agar pengguna dapat menilai keandalan dan keterbatasan keluaran AI, bukan sekadar memperlakukannya sebagai “kotak hitam” (black box). Dengan kata lain, agar prediksi AI tetap berbasis pada prinsip fisika, diperlukan pemahaman menyeluruh mengenai dinamika kebakaran, disertai validasi menggunakan simulasi kebakaran CFD yang memiliki fidelitas tinggi.



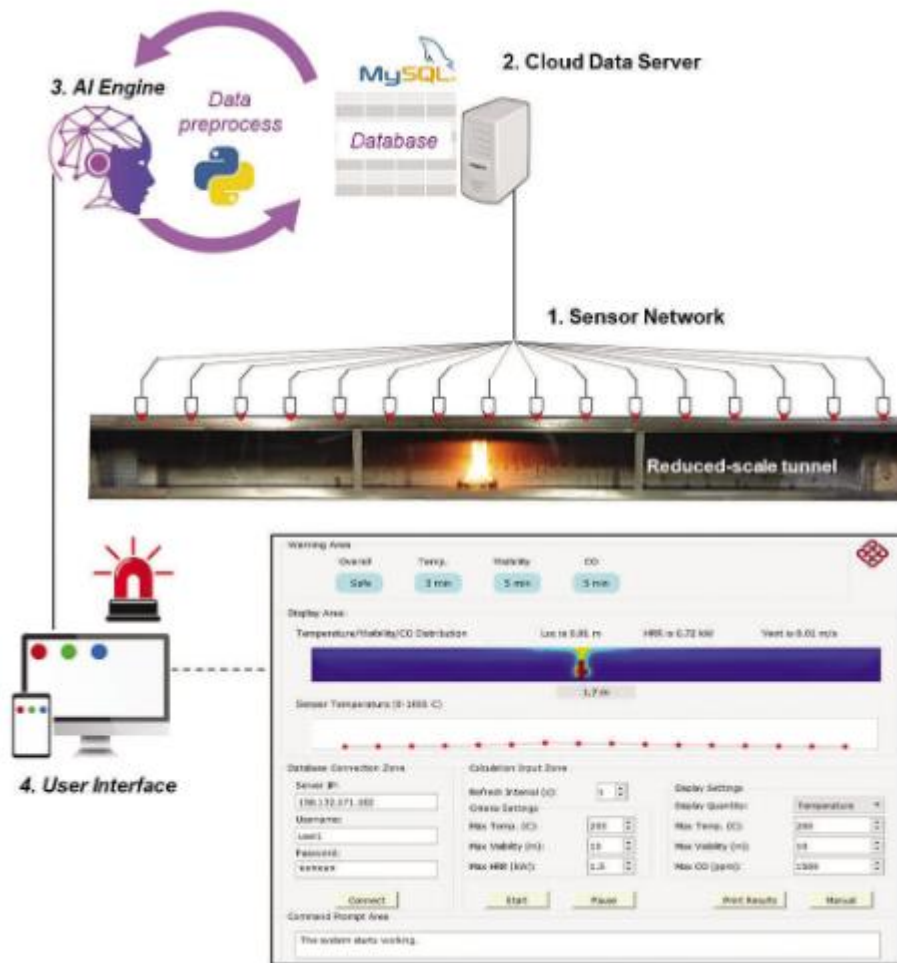
Gambar 18.6: Diagram struktur pembelajaran mendalam yang umum untuk (a) Jaringan saraf berulang (RNN), (b) memprediksi informasi skenario kebakaran, dan (c) meramalkan dan merender gambar lokasi kebakaran.

18.4 SISTEM MANAJEMEN KESELAMATAN KEBAKARAN TEROWONGAN CERDAS

Untuk mendemonstrasikan sistem pemadam kebakaran cerdas pada terowongan, dilakukan pengujian menggunakan model terowongan berskala kecil yang dilengkapi jaringan sensor *Internet of Things* (IoT) serta mesin AI yang telah dilatih dengan basis data numerik. Model terowongan dibuat dengan skala 1:50, memiliki panjang 1,7 m, tinggi 0,14 m, dan lebar 0,17 m. Bagian belakang, langit-langit, dan lantai terowongan dibuat dari pelat baja setebal 3 mm, sedangkan bagian depan menggunakan kaca tahan api setebal 3 mm untuk memudahkan observasi selama pengujian.

Dalam model numerik, kondisi batas dan domain komputasi disesuaikan dengan uji kebakaran skala kecil. Tiga parameter utama dipertimbangkan, yaitu lokasi kebakaran, ukuran kebakaran, dan kondisi ventilasi di dalam terowongan. Berdasarkan analisis skala dengan bilangan Froude, laju pelepasan panas (HRR) dan kecepatan aliran udara dapat diskalakan. Nilai parameter yang digunakan ditetapkan sesuai dengan praktik rekayasa dan analisis skala, sebagaimana tercantum dalam Tabel 18.3.

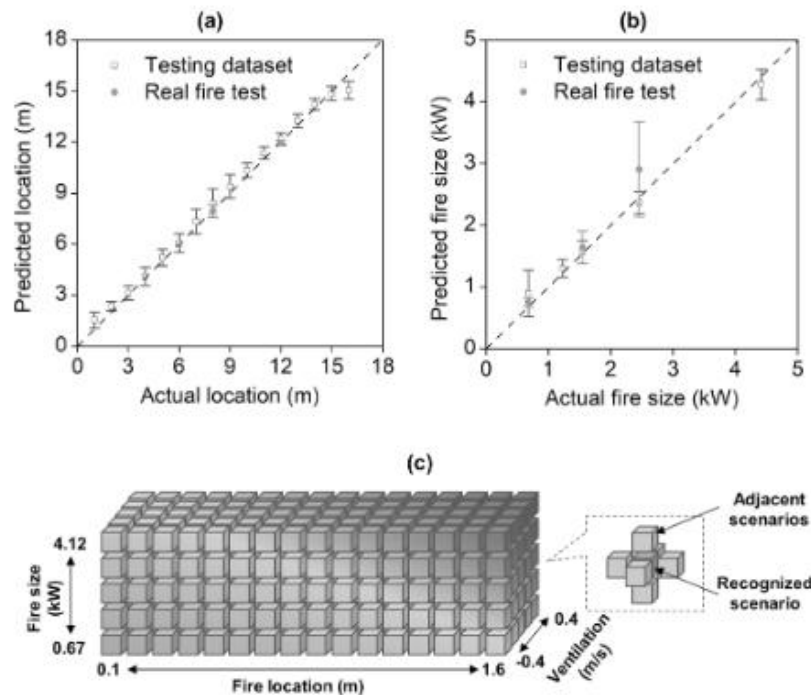
Secara keseluruhan, kombinasi 16 lokasi kebakaran, 5 nilai HRR, dan 5 kondisi ventilasi menghasilkan total 400 skenario kebakaran. Seluruh skenario dimodelkan menggunakan perangkat lunak *Fire Dynamics Simulator* (FDS) versi 6.7. Model tiga dimensi dari terowongan skala kecil dibangun dengan geometri serta material permukaan yang identik dengan model fisik. Sumber bahan bakar yang merepresentasikan kendaraan terbakar dimodelkan dengan pembakar berbentuk persegi. Untuk memastikan kesesuaian hasil, model CFD yang dikembangkan dikalibrasi melalui eksperimen laboratorium menggunakan nyala api dari bahan bakar cair, sehingga dapat merepresentasikan kondisi kebakaran terowongan secara lebih realistis.



Gambar 18.7 Pengaturan uji kebakaran terowongan skala kecil.

Tabel 18.3: Parameter utama kebakaran terowongan.

Parameter	Jumlah Nilai	Rentang Nilai
Ukuran api atau laju pelepasan panas (kW)	5	0.67, 1.23, 1.55, 2.45, 4.12
Lokasi kebakaran (m)	16	0.1–1.6 (interval 0.1)
Kecepatan ventilasi (m/s)	5	–0.4, –0.2, 0, 0.2, 0.4



Gambar 18.8: Prediksi (a) lokasi kebakaran dan (b) HRR pada dataset pengujian vs. data uji kebakaran sebenarnya, dan (c) perkembangan kondisi ventilasi yang diprediksi oleh model AI.


Untuk mendemonstrasikan kembaran digital kebakaran cerdas pada model terowongan, dilakukan pengujian dengan tiga sumber api berbahan bakar cair yang menghasilkan laju pelepasan panas (HRR) sebesar 0,67 kW, 1,55 kW, dan 2,45 kW. Sumber api tersebut ditempatkan di berbagai lokasi dalam terowongan. Distribusi suhu pada langit-langit terowongan diukur menggunakan pencatat data GL820 buatan Graphtec Corporation. Data hasil pengukuran kemudian diolah menjadi basis data eksperimental dengan prosedur yang serupa dengan pembentukan basis data numerik. Basis data eksperimental ini selanjutnya digunakan untuk mengevaluasi kemampuan model dalam memprediksi informasi skenario kebakaran secara nyata.

Hasil pengujian ditampilkan pada Gambar 18.8(a,b), yang menunjukkan prediksi skenario kebakaran dari uji terowongan berskala kecil, serta hasil perbandingan dari set data numerik. Secara umum, model AI yang telah dilatih menunjukkan kemampuan prediksi yang sebanding antara data eksperimen dan data numerik, bahkan dengan deviasi prediksi yang lebih rendah pada data uji nyata. Namun, prediksi kondisi ventilasi tidak dapat divalidasi karena keterbatasan data eksperimental.

Untuk menampilkan distribusi suhu secara temporospasial pada antarmuka pengguna, sistem perlu mengenali skenario kebakaran terlebih dahulu. Proses ini dilakukan dengan menghitung kesamaan menggunakan *mean squared error* (MSE) antara skenario kebakaran yang diprediksi dan skenario yang tersimpan dalam basis data. Semua skenario yang tersedia membentuk matriks skenario (Gambar 18.8c) dengan tiga dimensi utama, yaitu lokasi kebakaran (0,1 m hingga 1,6 m sepanjang terowongan), ukuran api (0,67 kW hingga 4,12 kW),

serta kondisi ventilasi ($-0,4$ m/s dengan arah aliran dari kanan ke kiri hingga $0,4$ m/s dengan arah sebaliknya).

Untuk menganalisis lebih jauh mekanisme prediksi, masukan model AI berupa data suhu terukur di berbagai titik dibandingkan dengan distribusi suhu hasil simulasi pada kondisi kuasi-stabil. Selanjutnya, suhu dari skenario yang dikenali dibandingkan dengan suhu skenario lain yang memiliki tingkat kemiripan paling tinggi, termasuk skenario-skenario berdekatan pada semua dimensi dalam matriks skenario.



Gambar 18.9: Perbandingan lokasi kebakaran yang diuji dan yang disesuaikan (kiri) serta profil suhu (kanan), di mana lokasi kebakaran dan ukuran kebakaran dalam hal HRR adalah: (a) 0,8 m dan 1,55 kW dan (b) 1,2 m dan 1,55 kW.

Gambar 18.9 mengilustrasikan perbandingan untuk kasus-kasus di mana api berada pada posisi yang berbeda dan terbakar pada HRR yang berbeda. Namun, tidak mudah untuk membedakan ukuran api dari distribusinya. Suhu maksimum untuk kasus-kasus dengan HRR berkisar antara $1,23$ kW hingga $2,45$ kW hampir sama dengan 800°C , alih-alih meningkat seiring dengan peningkatan HRR. Hal ini disebabkan oleh ukuran api yang begitu besar sehingga nyala api mengenai langit-langit terowongan, dan suhu maksimum pada dasarnya adalah suhu nyala api.

Dengan demikian, perbedaan utama keduanya terletak pada distribusinya masing-masing, bukan suhu maksimum. Semakin tinggi HRR api, semakin 'gemuk' bentuk distribusinya. Akhirnya, skenario yang diuji diidentifikasi dengan tepat memiliki HRR sebesar $1,55$ kW (Gambar 18.9a). Hal ini menunjukkan bahwa pengenalan model AI pada ukuran api tidak hanya bergantung pada suhu maksimum atau suhu di dekat sumber api. Sebaliknya, mekanisme yang lebih rumit dengan mempertimbangkan distribusi suhu dikembangkan oleh

model AI. Fenomena serupa diamati pada skenario kebakaran dengan lokasi kebakaran pada kedalaman 1,2 m (Gambar 18.9b).

Setelah skenario kebakaran dikenali, simulasi lokasi kebakaran, yang direpresentasikan oleh nilai HRR per satuan volume (HRRPUV) dan distribusi suhu, dapat diambil dari simulasi skenario kebakaran terkait yang tersimpan dalam basis data numerik. Seperti ditunjukkan di sisi kiri Gambar 18.9, lokasi kebakaran yang dikenali sangat mirip dengan eksperimen kebakaran. Citra distribusi suhu yang diambil dianggap sebagai Kembaran Digital Pemadam Kebakaran Cerdas dari terowongan skala kecil yang sebenarnya. Kemudian, kembaran digital tersebut ditampilkan di antarmuka pengguna secara waktu nyata (real-time) sebagai referensi.

18.5 KESIMPULAN DAN PERSPEKTIF

Bab ini mengulas perkembangan terkini penerapan teknologi AI dalam rekayasa keselamatan kebakaran terowongan dan pemadaman kebakaran cerdas. Konsep kunci dinamika kebakaran terowongan dan kejadian kebakaran kritis terkait diperkenalkan secara singkat. Tantangan dalam pengumpulan data kebakaran dari sensor dan simulasi numerik dibahas. Saat ini, seluruh komunitas teknik dan ilmiah juga kurang terbiasa dan standar dalam mencatat, mengorganisir, dan berbagi data, karena jumlah data tumbuh begitu cepat sehingga para peneliti tidak memiliki keterampilan analitis untuk menangani big data, terutama data kebakaran sementara dan video eksperimen/numerik. Pendekatan analitis data baru diperlukan dengan bantuan metode AI.

Kembaran digital kebakaran cerdas (SFDT) diusulkan untuk terowongan berdasarkan algoritma pembelajaran mendalam yang telah dilatih sebelumnya oleh ribuan simulasi kebakaran terowongan dan data lokasi kebakaran waktu nyata dari jaringan sensor. BMS masih belum banyak digunakan, dan sebagian besar tidak berbagi data dengan sistem lain. Kembaran Digital Bangunan yang lebih baru diusulkan untuk dibangun di atas BIM, tetapi tidak memiliki kapasitas untuk transfer dan manajemen data waktu nyata. Karena sensor IoT yang ada (detektor asap, panas, dan api) terhubung ke panel kontrol pusat, terdapat keuntungan besar dalam membentuk kembaran digital kebakaran dibandingkan sistem bangunan lainnya.

Terakhir, kami mengusulkan demonstrasi skala kecil sistem pemadam kebakaran pintar yang dapat memantau dan merender lokasi kebakaran terowongan serta memperkirakan perkembangan kebakaran. Penelitian selanjutnya sebaiknya memasukkan skenario kebakaran yang lebih realistis ke dalam basis data dan pelatihan model AI, seperti ukuran, bentuk, sudut kemiringan, dan penyumbatan terowongan, serta sumber api yang tumbuh/meluruh dan bergerak, dan lebih banyak sistem ventilasi.

Peningkatan basis data akan meningkatkan kapasitas prediksi AI secara signifikan. Model AI ini dapat diintegrasikan lebih lanjut dengan jaringan sensor nirkabel, server cloud, dan komputasi tepi untuk membentuk sistem pemadam kebakaran pintar. Sistem manajemen keselamatan kebakaran terowongan cerdas yang diusulkan merupakan bagian penting dari kembaran digital multi-fisik bangunan pintar di masa depan, dan dapat ditingkatkan lebih lanjut untuk manajemen keselamatan di berbagai jenis bangunan dan bahaya lainnya.

DAFTAR PUSTAKA

- Abdelkader, E. M., Al-Sakkaf, A., Elkabalawy, M., Omar, A., & Alfalah, G. (2025). Simulating the Deterioration Behavior of Tunnel Elements Using Amalgamation of Regression Trees and State-of-the-Art Metaheuristics. *Mathematics*, 13(7), 1021.
- Ajibade, O. M. AI-Powered Project Control Dashboards for Proactive Cybersecurity Event Response and Strategic Decision Support in Critical Infrastructure Programs.
- Akwaisua, A. M., Ekong, A., & Ansa, G. Enhancing Hazard Detection and Risk Severity Assessment in Construction through Multinomial Naive Bayes and Regression.
- Alotaibi, M. S., & Alshemmari, A. B. (2025). Artificial Intelligence in Smart Construction (Industry Readiness and Challenges in Implementation in Kuwait). *Ajrsp*, 6(72), 22-38.
- Ashraf, M., Ahmad, F., & Iqbal, I. (2025). Advanced Cybersecurity Strategies Leveraging Neural Networks for Protecting Critical Infrastructure against Evolving Digital Threats through Proactive Risk Management and Threat Intelligence. *IECE Transactions on Neural Computing*, 1(1), 44-54.
- Balamurugan, K., Adithyakumar, U., & Maharajan, M. P. (2025). New AI Technology. Machine Learning, Predictive Analytics, and Optimization in Complex Systems, 143.
- Balashova, Y., & Balashov, A. (2025, March). REVOLUTIONIZING TRANSPORTATION NETWORKS: AI-ENABLED SOLUTIONS FOR NEXT-GENERATION HIGHWAY SYSTEMS. In *Sworld-US Conference proceedings* (No. usc30-00, pp. 29-33).
- Batool, S. S., Adil, W. A., Talani, R. A., Raja, R., Abbas, S., & Bukhari, S. M. S. (2025). LEVERAGING AI TO IDENTIFY ANOMALIES IN ELECTRICAL SYSTEMS AND COMMUNICATION NETWORKS, SAFEGUARDING CRITICAL INFRASTRUCTURE AGAINST CYBER-ATTACKS. *Spectrum of Engineering Sciences*, 3(3), 452-472.
- CHEN, C., XIE, M., DU, Y., LI, S., & HUANG, Z. (2025). Dynamic monitoring and warning system for unstable rock collapse and its engineering application. *Chinese Journal of Engineering*, 47(7), 1423-1437.
- Comella, S., Milazzo, D., Cipolla, S., Aouedi, O., & Bonura, S. (2025, June). New Edge-to-Cloud Orchestrator for Intelligent Task Allocation and Efficiency Optimisation. In *2025 IEEE International Conference on Engineering, Technology, and Innovation (ICE/ITMC)* (pp. 1-8). IEEE.
- Dubey, H. (2025). Operational analytics in financial services: Enabling real-time decisions and strategic agility. *World Journal of Advanced Engineering Technology and Sciences*, 15(3), 1727-1765.

- Dwivedi, P., Khan, Z., Ansari, H., Chand, J., Singh, M. K., Sagheer, T., ... & Abbas, S. H. (2025). Predictive Maintenance and Monitoring of Industrial Compressors Using Machine Learning: A Proactive Approach. *Metallurgical and Materials Engineering*, 31(3), 372-381.
- El-Din Hemdan, E., & Al-Atroush, M. E. (2025). A review study of intelligent road crack detection: Algorithms and systems. *International Journal of Pavement Research and Technology*, 1-31.
- Frisch, P. (2025). *Fundamentals of the Intelligent Hospital: Adapting Diverse Enabling Technologies to Transform Healthcare Delivery*. Productivity Press.
- Gandhure, P., Khendare, R., Bhore, K., & Kolle, S. An Efficient Approach to Surveillance Car A Survey.
- Gangappa, M., Chandra, N. S., Kalpana, P., Kodati, S., & Dhasaratham, M. (2025). Smart Infrastructure Management: Leveraging Artificial Intelligence. *Recent Advances in Applied Sciences: Engineering and Technology Innovations*, 123.
- Garcia-Sáez, L. M., Ruiz-Villafranca, S., Roldan-Gómez, J., Carrillo-Mondejar, J., & Martinez, J. L. Federated Learning Under Attack: Threats, Challenges, and Defense Strategies. *Modelling, Data Analytics and AI in Engineering*.
- Gokulraj, G., Bose, S., Maheswaran, N., Danya, S., Pradeep Kumar, M., & Anitha, T. (2025, May). Harm-Aware IoT-Powered Smart Digital Fencing Framework for Real-Time Intrusion Detection and Mitigation Using Solar Energy. In *2025 2nd International Conference on Research Methodologies in Knowledge Management, Artificial Intelligence and Telecommunication Engineering (RMKMATE)* (pp. 1-7). IEEE.
- Harris, L. (2025). A Data-Driven Framework for Enhancing Transportation Safety through Proactive Planning and Management of Construction Activities in Urban Environments.
- Hartati, N. D., Puspitasari, N. R., Muizz, F. A., Rijaluddin, A., & Taufik, M. (2025). The Impact of Local Road Infrastructure on Driver Safety: A Systematic Literature Review. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(2), 5207-5218.
- Imbrosciano, M., Sciacca, E., Vitello, F., Pelonero, L., Franchina, F., Becciani, U., ... & Medić, D. (2025, March). The Cloud-HPC infrastructure for Hazard Mapping and vulnerability Monitoring (HaMMon). In *2025 33rd Euromicro International Conference on Parallel, Distributed, and Network-Based Processing (PDP)* (pp. 309-316). IEEE.
- Isaac, N., Singh, S., & Yurman, J. (2025). Utilizing Unmanned Aerial Systems for Asset Management, Maintenance, and Inspection in Railroad Projects. In *International Conference on Transportation and Development 2025* (pp. 810-820).

- Jaleel, A., Aziz, R., Farid, G., & Bashir, M. Z. (2025, May). The impact of ChatGPT on academic integrity in medical education: a developing nation perspective. In *Frontiers in Education* (Vol. 10, p. 1554444). Frontiers Media SA.
- Jones, J. F., Raj, V., Abas, P. E., Petra, M. I., Sivan, D., Satheesh Kumar, K., ... & Mathew, S. (2025). Application of artificial intelligence for asset integrity management of offshore oil and gas pipelines. *Life Cycle Reliability and Safety Engineering*, 1-28.
- Karri, H. V. R. (2025). *Next-Generation Smart Parking Systems: A Hybrid Framework for Secure Access and Real-Time Analytics* (Doctoral dissertation, CALIFORNIA STATE UNIVERSITY, NORTHRIDGE).
- Khaleghian, S. (2025). *AI-driven smart cities: Digital twin simulation, V2X communication, and EV infrastructure optimization*.
- Khatoon, A., Wang, W., Wang, M., Li, L., & Ullah, A. (2025). TinyML-enabled fuzzy logic for enhanced road anomaly detection in remote sensing. *Scientific Reports*, 15(1), 20659.
- Kulkarni, V., Sahoo, S. K., Nemade, B., Kallam, S., & Termritthikun, C. (2025). Exploring the power of AI and ML in smart grids: advancements, applications, and challenges. *Frontiers in Artificial Intelligence*, 8, 1615547.
- Kumar, R. S. (2025). *Cloud-Based Intrusion Detection Approach Using Machine Learning Techniques*. *JOURNAL OF COMPUTER SCIENCE* (ISSN NO: 1549-3636), 18(07).
- Kundu, S., & Swarnkar, S. (2025). A review of deep learning applications for suspended sediment load prediction. *Blue sky, blue water: strategies for protecting air and water quality in the 21st century*, 273-303.
- Li, S., Zhang, B., Tong, G., Li, Y., Liu, Z., Shi, B., ... & Gan, Z. (2025). Online Intelligent Monitoring System and Key Technologies for Dam Operation Safety. *Advances in Civil Engineering*, 2025(1), 9983255.
- Mashhadi, A., Black, C. W., & Wygonik, E. (2025). *Asset Condition Assessment Using AI and Computer Vision* (No. UT-25.12). Utah Department of Transportation.
- Namana, M. S. K., & Kumar, B. U. (2025). Enhancing Surveillance Systems leveraging AIoT for Advanced Object Detection in Real-Time Security Applications. *Engineering, Technology & Applied Science Research*, 15(3), 22507-22517.
- Nayak, L., Choudhary, B. K., Das, S., Chowdhury, M., & Halder, R. (2025). Smart System For Blood Donation And Availability Finder. *INTERNATIONAL JOURNAL OF ENGINEERING DEVELOPMENT AND RESEARCH*, 13(2), 254-266.
- Nithianandam, J. R. (2025). Advanced cloud analytics and artificial intelligence in healthcare: Medical image analysis for early disease detection and patient health monitoring. *World Journal of Advanced Engineering Technology and Sciences*, 15(3), 1182-1189.

- Nozari, H., Szmelter-Jarosz, A., & Samadi, S. (2025). Machine Learning Models for Energy Optimization and Resource Consumption in Smart Factories. In *Artificial Intelligence of Everything and Sustainable Development* (pp. 175-189). Singapore: Springer Nature Singapore.
- Ogirri, K. O. (2025). Leveraging AI-Driven Accounting for Sustainable Safety of Critical Infrastructure Projects. *Futurity Proceedings*, 2.
- Oluwaleke, A. (2025). Ai Development In Cybersecurity: Optimizing Defense While Mitigating Abuse And Adversarial Exploitation By Attackers. *Journal of Systematic and Modern Science Research*.
- Polu, A. R., Narra, B., Buddula, D. V. K. R., Patchipulusu, H. H. S., Vattikonda, N., & Gupta, A. K. (2025). The Role of the Internet of Things in Smart Cities: Current Implementations and Pathways for Future Development. *Universal Library of Engineering Technology*, 2(2).
- Ponnusamy, S., Assaf, M., Youssef, B., Jeon, G., & Kalyanaraman, S. (Eds.). (2025). *Leveraging VANETs and Blockchain Technology for Urban Mobility*. IGI Global.
- Prema, S., Apparna, C., & Gayathri, M. (2025, May). AI-Enabled Wildfire Risk Mapping & Emergency Navigation. In *2025 International Conference on Computational Robotics, Testing and Engineering Evaluation (ICCRTEE)* (pp. 1-6). IEEE.
- Qi, L., Peng, X., Yang, Q., Xia, K., & Xu, B. (2025). Review of Research on Prediction Models for Residual Life of Concrete Structures. *Coatings*, 15(6), 693.
- Rahman, K., & Iqbal, Q. (2025). Optimizing railway train selection in Pakistan using confidence-driven intuitionistic fuzzy methods with einstein-based operators. *J. Intell Manag. Decis*, 4(1), 66-77.
- Scaini, C., Petrovic, B., Scaini, A., Barnaba, C., & Peresan, A. (2025). Engaging diverse stakeholders: practical participatory tools for exposure data collection (No. EGU25-9198). *Copernicus Meetings*.
- Sharma, N., & Bhardwaj, M. (2025, March). A Review on Blockchain and Machine Learning in Healthcare. In *2025 International Conference on Next Generation Information System Engineering (NGISE)* (Vol. 1, pp. 1-6). IEEE.
- Sharma, N., & Kajal, A. (2025). Implementing Comparative Analysis on Feature Engineering Techniques and Multi-Model Evaluation Framework for IDS. *Journal of Cybersecurity & Information Management*, 16(1).
- Siddiqui, N., Azam, M., Khan, L., Zia-ul-Rehman, M., Altaf, M., & Hussain, A. (2025). Predictive Analytics for Accident Detection in Intelligent Traffic Systems: A Smart City Perspective. *Spectrum of Engineering Sciences*, 3(7), 668-679.

- Skaug, L. I., & Nojournian, M. Crash Probability-Aware Path Optimization: Road Risk Modeling for Safer Navigation Choices. Available at SSRN 5249991.
- Sminage, A., Delvin, P. B., Davies, D., Vivek, K. J., & Davies, J. (2025, April). SafeDrive: Intelligent Pothole Detection and Mapping System. In 2025 2nd International Conference on Trends in Engineering Systems and Technologies (ICTEST) (Vol. 1, pp. 1-6). IEEE.
- Vedrtnam, A., Wyche, K. P., Chauhan, B. V., & Verma, S. (2025). Introduction to the Prospects of Artificial Intelligence in the Environment. In Prospects of Artificial Intelligence in the Environment (pp. 1-27). Singapore: Springer Nature Singapore.
- Vijayalakshmi, S., Bose, S., Logeswari, G., & Maheswaran, N. (2025). Smart parking: intelligent intrusion detection system in VANET enabled car parking system. *Automatika*, 66(2), 281-299.
- William, P., Jaiswal, V. K., Shrivastava, A., Kumar, Y., Shakir, A. M., & Gupta, M. (2025, May). IOT Based Smart Cities Evolution of Applications, Architectures & Technologies. In 2025 International Conference on Engineering, Technology & Management (ICETM) (pp. 1-6). IEEE.
- Xia, B. (2025). Operationalising Safe and Responsible AI: A System Level Perspective (Doctoral dissertation, UNSW Sydney).
- Yadav, M. R., & Ashesh, G. (2025). E-Governance 4.0: Integrating AI and IoT for Sustainable and Smart Management of Maha Kumbh 2025. *International Journal of Latest Technology in Engineering, Management & Applied Science*, 14(3), 426-433.

Penerapan AI

Pada Infrastruktur, Rekayasa Teknik Sipil dan Konstruksi

Dr. Agus Wibowo, M.Kom, M.Si, MM.

BIO DATA PENULIS



Penulis memiliki berbagai disiplin ilmu yang diperoleh dari Universitas Diponegoro (UNDIP) Semarang. dan dari Universitas Kristen Satya Wacana (UKSW) Salatiga. Disiplin ilmu itu antara lain teknik elektro, komputer, manajemen dan ilmu sosiologi. Penulis memiliki pengalaman kerja pada industri elektronik dan sertifikasi keahlian dalam bidang Jaringan Internet, Telekomunikasi, Artificial Intelligence, Internet Of Things (IoT), Augmented Reality (AR), Technopreneurship, Internet Marketing dan bidang pengolahan dan analisa data (komputer statistik).

Penulis adalah pendiri dari Universitas Sains dan Teknologi Komputer (Universitas STEKOM) dan juga seorang dosen yang memiliki Jabatan Fungsional Akademik Lektor Kepala (Associate Professor) yang telah menghasilkan puluhan Buku Ajar ber ISBN, HAKI dari beberapa karya cipta dan Hak Paten pada produk IPTEK. Sejak tahun 2023 penulis tercatat sebagai Dosen luar biasa di Fakultas Ekonomi & Bisnis (FEB) Universitas Diponegoro Semarang. Penulis juga terlibat dalam berbagai organisasi profesi dan industri yang terkait dengan dunia usaha dan industri, khususnya dalam pengembangan sumber daya manusia yang unggul untuk memenuhi kebutuhan dunia kerja secara nyata.



YAYASAN PRIMA AGUS TEKNIK

PENERBIT :

YAYASAN PRIMA AGUS TEKNIK
Jl. Majapahit No. 605 Semarang
Telp. (024) 6723456. Fax. 024-6710144
Email : penerbit_ypat@stekom.ac.id

ISBN 978-634-7227-39-3 (PDF)



9

786347

227393