


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

# Struktur Bangunan Gridshell elastis GFRP memakai Pembelajaran Mesin (ML)



YAYASAN PRIMA AGUS TEKNIK

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

# Struktur Bangunan Gridshell elastis GFRP memakai Pembelajaran Mesin (ML)



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 978-634-7695-15-4 (PDF)



9

786347

695154

**Struktur Bangunan Gridshell elastis GFRP  
memakai Pembelajaran Mesin (ML)**

**Penulis :**

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

**ISBN : 978-634-7695-15-4 (PDF)**

**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](mailto:penerbit_ypat@stekom.ac.id)

**Distributor Tunggal :**

**Universitas STEKOM**

Jl. Majapahit no 605 Semarang

Telp. 08122925000

Fax. 024-6710144

Email : [info@stekom.ac.id](mailto: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 ke hadirat Tuhan Yang Maha Esa atas rahmat-Nya sehingga buku *“Struktur Bangunan Gridshell Elastis GFRP memakai Pembelajaran Mesin (ML)”* ini dapat terselesaikan dengan baik. Dalam landscape rekayasa struktur abad ke-21, struktur gridshell elastis berbasis *Glass Fiber Reinforced Polymer* (GFRP) muncul sebagai paradigma baru yang memadukan keindahan bentuk organik, efisiensi material, dan adaptabilitas konstruksi. Buku ini, secara khusus menjawab kebutuhan mendesak akan metodologi desain cerdas yang mengintegrasikan Pembelajaran Mesin (ML) untuk memprediksi, menganalisis, dan mengoptimalkan perilaku struktur GFRP selama proses pengangkatan dan pemasangan. Inspirasi utama berasal dari proyek-proyek pionir seperti gridshell kayu elastis di Weald & Downland Museum, yang kini ditingkatkan dengan material komposit GFRP untuk ketahanan lebih tinggi terhadap korosi dan beban dinamis, khususnya di iklim tropis seperti Indonesia.

Tantangan utama gridshell GFRP terletak pada sifat elastisnya yang menyebabkan deformasi signifikan saat pengangkatan, memerlukan prediksi akurat untuk memastikan bentuk akhir sesuai desain. Buku ini mengusung solusi inovatif melalui ML, mulai dari model prediksi deformasi hingga optimasi multi-objektif, yang dapat mengurangi iterasi desain secara drastis dan meningkatkan keamanan struktural. Struktur buku dirancang progresif, dari fondasi teori hingga aplikasi praktis, dengan setiap bab membangun atas yang sebelumnya.

Bab 1: Struktur Gridshell Elastis GFRP dan Pembelajaran Mesin membuka pintu dengan pendahuluan mendalam tentang latar belakang evolusi gridshell, definisi masalah deformasi elastis, serta tujuan utama: peningkatan ML untuk desain GFRP. Kerangka desain berbasis ML dan struktur buku keseluruhan diuraikan di sini, menyiapkan pembaca untuk perjalanan analitis yang sistematis.

Bab 2: Struktur Gridshell GFRP dan Algoritma Pembelajaran Mesin menyajikan tinjauan komprehensif tentang aplikasi ML dalam gridshell, desain cangkang grid elastis GFRP, proses pemasangan, serta peluang dan tantangan inovasi. Bab ini juga mendalami kecerdasan buatan, model ML (termasuk pendekatan yang dapat diinterpretasikan), metode pengembangan algoritma, indikator kinerja akurasi, algoritma optimasi Swarm Partikel Multi-Objektif (MOPSO), analisis elemen hingga, dan desain gridshell elastis dengan ML—menjadi pondasi teori yang kokoh.

Bab 3: Prediksi Bentuk Batang Ramping Diskrit fokus pada konstruksi pengangkatan dan analisis diskrit gridshell, dengan metodologi rinci untuk proses pengangkatan. Analisis balok kantilever (analitik vs. ML) dan prediksi deformasi menggunakan WL-E-TSVM dieksplorasi secara mendalam, memberikan alat prediksi presisi untuk elemen dasar gridshell. Bab 4: Prediksi Bentuk Gridshell GFRP saat Pengangkatan melanjutkan dengan kemajuan prediksi bentuk, analisis diskrit deformasi pengangkatan, serta contoh numerik konkret seperti kubah tong dan struktur gridshell lainnya. Prediksi menggunakan WL-E-TSVM divalidasi melalui simulasi, menunjukkan akurasi tinggi dalam skenario real-world.

Bab 5: Penentuan Bentuk Gridshell GFRP Pengangkatan meninjau metode pencarian bentuk, analisis untuk gridshell, contoh numerik ekstensif, dan pencarian bentuk optimal—menghasilkan workflow lengkap untuk insinyur yang siap diterapkan di lapangan. Bab 6: Penilaian Kinerja Struktural Gridshell Elastis GFRP membahas analisis struktural dengan ML, proses analisis, prediksi tekanan, rasio pergeseran terhadap berat sendiri, serta model CatBoost untuk prediksi kinerja keseluruhan—memastikan struktur tidak hanya indah, tapi juga aman di bawah beban ekstrem.

Bab 7: Optimasi Struktural Cangkang Kisi Elastis GFRP mengintegrasikan optimasi bentuk dengan MOPSO, prediksi kinerja struktural, proses optimasi, serta perbandingan ML vs. metode konvensional dan antar model ML dengan optimasi bentuk—menyajikan hasil benchmark yang menonjolkan superioritas pendekatan hibrida. Bab 8: Kesimpulan dan Rekomendasi Desain dan Optimasi Gridshell merangkum aplikasi ML dalam desain dan optimasi GFRP, diikuti rekomendasi observasi masa depan seperti integrasi sensor IoT atau ML real-time, membuka horizon penelitian baru.

Ucapan terima kasih yang tulus dan mendalam disampaikan kepada seluruh tim observasi yang telah berkolaborasi dalam simulasi dan validasi data; para dosen pembimbing dan institusi mitra internasional yang memberikan arahan kritis; mitra industri produsen GFRP serta software simulasi yang menyediakan akses data lapangan; keluarga tercinta yang menjadi pilar dukungan emosional sepanjang proses penelitian panjang ini; serta semua rekan mahasiswa dan profesional yang telah berbagi insight berharga melalui diskusi dan workshop. Tanpa kontribusi kalian, karya ini takkan terwujud. Kepada para pembaca yang terhormat—insinyur visioner, arsitek inovatif, dan peneliti penuh semangat, selamat menjelajahi halaman-halaman ini.

Semoga buku ini tidak hanya menjadi panduan teknis yang andal, melainkan juga pemicu revolusi dalam desain struktur elastis, menginspirasi Anda untuk mewujudkan gridshell GFRP cerdas yang membentuk kota-kota berkelanjutan, tahan gempa, dan estetis di masa depan. Mari bersama-sama membangun warisan rekayasa yang abadi, di mana teknologi ML dan material mutakhir bersatu demi kesejahteraan umat manusia.

*Selamat & Semangat Membaca...!!!*

Semarang, Maret 2026  
Penulis

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

# DAFTAR ISI

<b>KATA PENGANTAR.....</b>	<b>i</b>
<b>DAFTAR ISI.....</b>	<b>iii</b>
<b>BAB 1 STRUKTUR GRID SHELL ELASTIS GFRP DAN PEMBELAJARAN MESIN.....</b>	<b>1</b>
1.1 Pendahuluan.....	1
1.2 Latar Belakang Gridshell Elastis GFRP .....	3
1.3 Definisi Masalah .....	4
1.4 Tujuan: Peningkatan ML Untuk Desain Gridshell GFRP.....	7
1.5 Kerangka Desain Gridshell GFRP Berbasis ML.....	7
1.6 Struktur Buku: Tinjauan Hingga Optimasi Gridshell.....	8
<b>BAB 2 STRUKTUR GRID SHELL GFRP DAN ALGORITMA PEMBELAJARAN MESIN.....</b>	<b>10</b>
2.1 Tinjauan Gridshell Dan Aplikasi ML.....	10
2.2 Struktur Gridshell Elastis GFRP .....	11
2.3 Desain Cangkang Grid Elastis GFRP .....	13
2.4 Proses Pemasangan.....	15
2.5 Peluang Inovasi Cangkang Kisi GFRP .....	15
2.6 Tantangan Cangkang Jaring GFRP.....	17
2.7 Kecerdasan Buatan .....	18
2.8 Pembelajaran Mesin.....	18
2.9 Model Pembelajaran Mesin .....	19
2.10 Pendekatan Pembelajaran Mesin Yang Dapat Diinterpretasikan.....	34
2.11 Metode Pengembangan Untuk Algoritma ML .....	36
2.12 Indikator Kinerja Akurasi .....	39
2.13 Algoritma Optimasi Swarm Partikel Multi-Objektif.....	39
2.14 Analisis Elemen Hingga.....	40
2.15 Desain Gridshell Elastis GFRP Dengan ML.....	41
<b>BAB 3 PREDIKSI BENTUK BATANG RAMPING DISKRIT .....</b>	<b>43</b>
3.1 Konstruksi Pengangkatan & Analisis Diskrit Gridshell .....	43
3.2 Proses Konstruksi Pengangkatan .....	43
3.3 Metodologi .....	44
3.4 Analisis Balok Kantilever: Analitik & ML.....	50
3.5 Prediksi Deformasi Balok Dengan WL-E-TSVM.....	60
<b>BAB 4 PREDIKSI BENTUK GRID SHELL GFRP SAAT PENGANGKATAN .....</b>	<b>61</b>
4.1 Kemajuan Prediksi Bentuk Gridshell GFRP .....	61
4.2 Analisis Diskrit & Prediksi Deformasi Pengangkatan .....	62
4.3 Contoh Numerik Dari Kubah Tong.....	66
4.4 Contoh Numerik Struktur Gridshell.....	71
4.5 Prediksi Bentuk Gridshell GFRP Dengan WL-E-TSVM.....	82
<b>BAB 5 PENENTUAN BENTUK GRID SHELL GFRP PENGANGKATAN .....</b>	<b>84</b>

5.1	Tinjauan Metode Pencarian Bentuk Gridshell.....	84
5.2	Metode Analisis Untuk Gridshell.....	85
5.3	Contoh Numerik .....	87
5.4	Pencarian Bentuk Gridshell GFRP Pengangkatan .....	104
<b>BAB 6</b>	<b>PENILAIAN KINERJA STRUKTURAL GRIDSHELL ELASTIS GFRP .....</b>	<b>106</b>
6.1	Analisis Struktural Gridshell GFRP Dengan ML.....	106
6.2	Proses Analisis Struktural .....	107
6.3	Prediksi Tekanan .....	109
6.4	Prediksi Rasio Pergeseran Terhadap Berat Sendiri .....	117
6.5	Prediksi Kinerja Gridshell GFRP: CatBoost.....	126
<b>BAB 7</b>	<b>OPTIMASI STRUKTURAL CANGKANG KISI ELASTIS GFRP .....</b>	<b>127</b>
7.1	Optimasi Bentuk Gridshell Dengan MOPSO .....	127
7.2	Prediksi Kinerja Struktural .....	128
7.3	Optimasi Struktural .....	128
7.4	Perbandingan ML & Optimasi Gridshell GFRP.....	130
7.5	Perbandingan Model ML Dan Optimasi Bentuk Gridshell GFRP.....	167
<b>BAB 8</b>	<b>KESIMPULAN DAN REKOMENDASI DESAIN DAN OPTIMASI GRIDSHELL .....</b>	<b>169</b>
8.1	Aplikasi ML Untuk Desain Dan Optimasi Gridshell GFRP .....	169
8.2	Rekomendasi Observasi Masa Depan .....	171
<b>DAFTAR PUSTAKA</b>	<b>.....</b>	<b>172</b>

## **BAB 1**

### **STRUKTUR GRID SHELL ELASTIS GFRP DAN PEMBELAJARAN MESIN**

#### **1.1 PENDAHULUAN**

Struktur gridshell elastis polimer yang diperkuat serat kaca (GFRP) adalah jenis struktur ringan yang dibangun dengan mendeformasi kisi datar awal yang terdiri dari elemen-elemen ramping. Beban tegak lurus dapat mendeformasi kisi datar ini untuk mencapai bentuk yang diinginkan. Menyelesaikan berbagai masalah yang berkaitan dengan struktur gridshell elastis GFRP menggunakan metode tradisional biasanya rumit dan memakan waktu. Oleh karena itu, membangun pendekatan pengganti yang efisien sangat penting. Model pembelajaran mesin (ML) menawarkan beberapa keunggulan dibandingkan pendekatan tradisional dan teknik meta-pemodelan lainnya.

Observasi ini memperluas penerapan model ML di bidang struktur gridshell elastis GFRP, sebagian menggantikan teknik komputasi tradisional yang memakan waktu dengan pendekatan yang cerdas, efisien, dan hemat waktu. Observasi ini pertama-tama menyajikan algoritma ML yang dapat digunakan untuk desain struktural dan optimasi gridshell elastis GFRP, termasuk regresi linier (LR), regresi ridge (RR), *K-nearest neighbors* (KNN), pohon keputusan (DT), *random forest* (RF), AdaBoost, XGBoost, CatBoost, LightGBM, jaringan saraf tiruan (ANN), *support vector machine* (SVM), dan enam bentuk SVM yang ditingkatkan.

Selanjutnya, pendekatan ML yang dapat diinterpretasikan, seperti plot ketergantungan parsial (PDP), efek lokal terakumulasi (ALE), dan penjelasan aditif Shapley (SHAP), diperkenalkan. Selain itu, beberapa metode untuk mengembangkan algoritma ML, termasuk validasi silang K-fold (CV), metode Taguchi, teknik untuk preferensi urutan berdasarkan kesamaan dengan solusi ideal (TOPSIS), dan optimasi swarm partikel multi-objektif (MOPSO), diusulkan. Algoritma-algoritma ini diimplementasikan untuk meningkatkan aplikasi struktur gridshell menggunakan representasi komprehensif dari model ML.

Selanjutnya, analisis observasi dilakukan sebagai berikut:

1. Prediksi bentuk batang GFRP ramping dilakukan dengan memperkenalkan teori model elemen diskrit, diikuti dengan validasi menggunakan analisis elemen hingga (FEA). Selain itu, model ML diterapkan untuk prediksi bentuk.
2. Prediksi bentuk struktur gridshell lebih lanjut dilakukan dengan mempertimbangkan deformasi elemen diskrit menggunakan pendekatan ML. Kebaruannya terletak pada pemanfaatan karakteristik elemen diskrit untuk mempersiapkan dataset, daripada langsung bergantung pada analisis seluruh struktur yang memakan waktu. Model ML digunakan untuk menganalisis kubah barel dan gridshell simetris biaxial, dengan mempertimbangkan deformasi geometris yang signifikan.
3. Analisis pencarian bentuk gridshell GFRP selama fase konstruksi pengangkatan dilakukan menggunakan pendekatan ML yang dapat diinterpretasikan, menghasilkan tata letak optimal untuk kisi datar asli. Hasil FEA juga digunakan untuk validasi.

4. Model ML diimplementasikan untuk memprediksi perilaku struktural struktur gridshell, diikuti dengan studi perbandingan berbagai algoritma ML. Pendekatan ML yang dapat diinterpretasikan lebih lanjut digunakan untuk menjelaskan pengaruh parameter desain.
5. Optimasi bentuk dilakukan menggunakan tiga algoritma yaitu weighted Lagrange  $\epsilon$ -twin support vector machine (WL- $\epsilon$ -TSVM), MOPSO, dan TOPSIS, untuk mendapatkan bentuk optimal struktur gridshell yang bertujuan untuk meningkatkan kinerja struktural. Pendekatan Taguchi digunakan untuk menyempurnakan parameter algoritma MOPSO.

Hasil inovatif mengenai desain struktural dan optimasi gridshell elastis GFRP menggunakan metode ML dirangkum sebagai berikut. Dua metode baru dan efisien, satu berdasarkan teori analitik dan yang lainnya berdasarkan model ML, diusulkan untuk menganalisis elemen yang diangkat.

Metode ini sangat efektif untuk memperkirakan deformasi dan momen lentur elemen ramping selama proses pengangkatan, yang melibatkan deformasi geometris yang signifikan. Kebaruan pendekatan ini terletak pada persiapan dataset menggunakan karakteristik elemen diskrit, daripada menganalisis seluruh struktur, yang akan memakan biaya komputasi yang mahal. Metode yang diusulkan untuk struktur gridshell elastis, yang juga memanfaatkan model ML, secara efektif memperkirakan deformasi dan momen lentur selama konstruksi pengangkatan gridshell. Selain itu, bentuk kisi datar asli yang diperoleh melalui metode pencarian bentuk baru menunjukkan keandalan yang tinggi untuk struktur gridshell, karena kesalahan minimal terjadi selama proses pengangkatan dan pemasangan. Pendekatan ini memperkenalkan perspektif baru dengan mengintegrasikan pencarian bentuk dengan teknik ML dan interpretasi.

Studi perbandingan dalam observasi ini menunjukkan bahwa algoritma WL- $\epsilon$ -TSVM, LightGBM, dan CatBoost mengungguli metode lain dalam memprediksi perilaku struktur gridshell GFRP pasca-konstruksi. Model-model ini memberikan penilaian kinerja struktural yang cepat dan berharga dengan akurasi yang dapat diterima. Selain itu, metode interpretasi seperti PDP, ALE, dan SHAP diperlukan untuk penjelasan komprehensif dari model ML.

Metode optimasi bentuk hibrida baru yang disajikan untuk gridshell GFRP berhasil mengidentifikasi bentuk optimal struktur, memastikan kinerja struktural yang sangat baik. Akurasi dan efisiensi kerangka kerja yang diusulkan diverifikasi oleh keluaran FEA. Observasi ini sangat inovatif karena belum ada observasi sebelumnya yang mengembangkan model ML untuk meningkatkan aplikasi struktur gridshell elastis GFRP.

Kesimpulannya, observasi ini memperkenalkan kerangka kerja baru untuk prediksi bentuk, pencarian bentuk, penilaian kinerja struktural, dan optimasi bentuk gridshell elastis GFRP yang dapat membentuk sendiri selama pengangkatan, menggunakan metode ML. Kemajuan ini bertujuan untuk meningkatkan tingkat keberhasilan proyek yang melibatkan struktur tersebut.

## **1.2 LATAR BELAKANG GRIDSHELL ELASTIS GFRP**

### **Struktur Gridshell Elastis GFRP**

Sistem struktur ringan yang dikenal sebagai gridshell semakin banyak digunakan saat ini karena kemampuannya untuk menggabungkan estetika ekspresif dengan kebebasan arsitektur, secara efektif menutupi ruang besar sambil mengoptimalkan penggunaan material. Didefinisikan sebagai grid balok seperti jaring yang membentuk permukaan melengkung ganda seperti cangkang dan bentuk bebas yang lancar, gridshell dirancang untuk mentransfer beban seefisien mungkin dengan mengaktifkan konfigurasi bentuknya dalam resistensi. Sebagai struktur ringan yang aktif bentuknya, gridshell semakin populer karena desainnya yang kompleks namun sangat efisien. Mereka tidak hanya menawarkan desain bentuk bebas yang ekspresif secara artistik tetapi juga mengurangi jejak ekologis, meningkatkan keberlanjutan, dan memberikan kebebasan desain yang signifikan sambil meminimalkan penggunaan material.

Gridshell elastis awalnya dibangun dari kayu, tetapi kekurangan alami yang melekat pada material tersebut membatasi kekuatannya. Selama beberapa dekade, kemajuan struktur cangkang jaring elastis terhambat oleh kurangnya metode dan material desain yang sesuai hingga diperkenalkannya polimer yang diperkuat serat kaca (GFRP) ke dalam aplikasi tersebut. Douthe et al. dan Caron et al. membandingkan GFRP dengan material konstruksi lainnya dan menemukan bahwa GFRP dapat digunakan secara efektif dalam struktur cangkang jaring elastis dan sistem prategang ringan lainnya. Dalam hal sifat mekanik, GFRP melampaui kayu, menawarkan regangan batas elastis, kekuatan, dan ketahanan yang unggul, yang secara signifikan meningkatkan kapasitas daya dukung dan kekakuan struktur cangkang jaring.

Efisiensi sistem struktur cangkang jaring semakin mendapat perhatian dalam bidang teknik struktur kontemporer, dengan fokus pada pengurangan waktu komputasi, peningkatan efisiensi struktural, dan peningkatan metodologi desain sambil mengatasi proses manufaktur. Sebagai hasil dari peningkatan penekanan pada efisiensi ini, model pembelajaran mesin (ML) semakin banyak diimplementasikan untuk menyederhanakan proses, mengoptimalkan desain, dan menciptakan sistem yang lebih adaptif dan cerdas. Kemajuan ini siap untuk mentransformasi industri dengan menyediakan alat komputasi yang lebih akurat dan cepat yang dapat menghasilkan solusi struktural yang lebih berkelanjutan dan hemat biaya.

### **Pembelajaran Mesin**

Kecerdasan buatan (AI) mengacu pada konsep umum mesin yang melakukan tugas secara mandiri dengan menciptakan model yang memungkinkan komputer dan robot untuk beroperasi secara cerdas. Prinsip inti AI adalah belajar dari data untuk secara efektif mensimulasikan hubungan praktis yang kompleks dalam data, bahkan ketika fenomena fisik sulit untuk diinterpretasikan atau ketergantungan yang mendasarinya tidak diketahui. Salehi dan Burgueno menguraikan metodologi yang telah dikembangkan untuk menerapkan alat AI yang mapan pada teknik struktur. Dalam teknik struktur, ML dianggap sebagai salah satu teknik AI yang paling menjanjikan.

ML adalah subset dari AI yang berfokus pada pengembangan model untuk membuat prediksi yang akurat. Secara khusus, ML memanfaatkan metode statistik, karena fokus

utamanya adalah pada inferensi pola dari data, untuk meningkatkan model yang ada berdasarkan pengalaman sebelumnya dan tren yang telah ditetapkan. Pelatihan algoritma ML bergantung pada ketersediaan data yang akurat dan bersih untuk memberikan hasil yang andal, dan membutuhkan kumpulan data yang besar untuk memastikan penerapannya di berbagai skenario masa depan. Beberapa algoritma ML tersedia dalam literatur, dan dapat dikategorikan menjadi tiga kelompok utama. Kelompok pertama adalah pembelajaran terawasi dan termasuk dalam kategori prediktif ML. Kelompok kedua adalah pembelajaran tak terawasi dan termasuk dalam kategori preskriptif ML. Ketiga adalah pembelajaran penguatan yang digunakan untuk menentukan respons atau tindakan yang tepat dalam lingkungan yang tidak pasti.

Karena metode tradisional, seperti analisis elemen hingga (FEA), untuk sistem struktur yang kompleks biasanya memerlukan sumber daya komputasi yang signifikan dan kalibrasi yang memakan waktu, ML seringkali dapat menawarkan alternatif yang berharga untuk mengatasi masalah kompleks dalam rekayasa struktur. Demikian pula, BIM dapat mengintegrasikan teknik AI dan ML untuk mengoptimalkan seluruh siklus hidup proyek konstruksi. Lingkungan yang kaya data dari pemodelan informasi bangunan (BIM) menyediakan landasan bagi algoritma AI untuk menghasilkan wawasan, mengotomatiskan proses, dan meningkatkan pengambilan keputusan dalam desain struktural, prediksi kinerja, dan manajemen fasilitas, yang mengarah pada solusi yang lebih efisien, berkelanjutan, dan hemat biaya.

### **1.3 DEFINISI MASALAH**

Struktur ringan, seperti sistem struktural lainnya, dirancang untuk menahan tekanan eksternal dan menjaga integritas lingkungan internal. Namun, tujuan utamanya adalah untuk mencapai hal ini seefisien mungkin dengan mengoptimalkan karakteristiknya. Tantangannya terletak pada kurangnya informasi struktural yang tersedia, yang menghambat potensi penuh dari sistem ini untuk direalisasikan. Selain itu, masalah rekayasa struktural yang kompleks tidak dapat ditangani secara efektif atau dipahami sepenuhnya menggunakan metode tradisional. Hal ini disebabkan oleh kurangnya pemahaman mekanis tentang fenomena yang rumit dan ketergantungan pada penyederhanaan atau asumsi abstrak yang melekat dalam pendekatan konvensional ini.

Kinerja struktur cangkang jaring dipengaruhi oleh beberapa faktor, termasuk beban, bentuk batas, penampang elemen, ukuran jaring, tinggi, dan metode konstruksi; hal ini membuat prediksi akurat perilaku strukturalnya menjadi proses yang kompleks. Algoritma ML, yang mengandalkan pembelajaran dari pasangan data input-output untuk menetapkan parameter model, menawarkan solusi yang ampuh dengan menghilangkan kebutuhan akan asumsi atau penyederhanaan masalah. Model-model ini dapat diperbarui secara berkala dengan data baru untuk meningkatkan akurasi prediksi. Akibatnya, ML diharapkan menjadi alat yang andal dalam berbagai aplikasi teknik struktur. Dalam kasus struktur cangkang jaring, model ML dapat membantu mengatasi beberapa tantangan, khususnya dalam metode desain optimal, yang merupakan isu kunci untuk keberhasilan penerapan struktur cangkang jaring



elastis GFRP. Desain optimal melibatkan tugas-tugas seperti prediksi bentuk, pencarian bentuk, penilaian kinerja struktural, dan optimasi keseluruhan.

### **Prediksi Bentuk**

Karena nonlinieritas geometris yang cukup besar, mekanisme pembentukan bentuk struktur cangkang jaring elastis secara inheren kompleks. Oleh karena itu, sangat penting untuk menghitung secara akurat bentuk deformasi struktur ini, dengan mempertimbangkan sifat mekaniknya. Maka, penting untuk mengeksplorasi kemungkinan menghitung deformasi dengan menganalisis model sederhana yang terdiri dari elemen diskrit yang dikenai gaya terpusat dan beban terdistribusi. Mengingat bahwa berbagai bentuk dapat muncul di bawah berbagai kondisi beban, diperlukan teknik yang kuat untuk memprediksi bentuk struktural. Oleh karena itu, dengan mempelajari elemen diskrit dan menggunakan pendekatan teknik lunak, bentuk gridshell dapat diprediksi secara efektif.

Di bidang ini, masalah biasanya tidak terstruktur dan tidak tepat, sering dipengaruhi oleh pengalaman dan intuisi sebelumnya dari seorang perancang. Pendekatan komputer tradisional yang bergantung pada hubungan analitis atau empiris cenderung memakan banyak tenaga dan waktu ketika berurusan dengan masalah kehidupan nyata. Untuk mengatasi tantangan tersebut, metode komputasi lunak berbasis komputer yang mendekati, yang terinspirasi oleh penalaran, intuisi, kesadaran, dan kebijaksanaan manusia, semakin banyak diterapkan untuk mengeksplorasi, mensimulasikan, dan mengevaluasi masalah kompleks. Akibatnya, penerapan metode ML, yang merupakan bagian dari pendekatan komputasi lunak, harus dipertimbangkan untuk prediksi bentuk gridshell.

### **Pencarian Bentuk**

Desain gridshell sangat dipengaruhi oleh aliran gaya, yang mengharuskan penggunaan prosedur pencarian bentuk untuk mendefinisikan bentuknya. Selain itu, integrasi fitur arsitektur, mekanik, atau teknis ke dalam bentuk gridshell yang optimal mungkin memerlukan beberapa bentuk optimasi, sehingga proses desain secara keseluruhan memakan waktu. Salah satu aspek paling menantang dalam mendesain struktur cangkang jaring elastis adalah menentukan kisi datar yang dapat diterima yang pada akhirnya akan menghasilkan bentuk yang diinginkan, yang merupakan komponen kunci dari prosedur pencarian bentuk untuk sistem struktur tersebut. Prosedur ini merupakan proses maju di mana variabel dimanipulasi untuk mencapai bentuk ideal dalam keseimbangan statis. Biasanya, beban desain untuk struktur cangkang jaring terdiri dari beban mati, yang terutama adalah beratnya sendiri. Tujuan dari pencarian bentuk adalah untuk mengidentifikasi struktur yang berada dalam keadaan keseimbangan gaya. Dalam prosedur pembentukan struktur cangkang kisi (gridshell), metode konstruksi dan koordinat ujung elemen, khususnya koordinat  $z$ , memainkan peran penting dalam membentuk struktur akhir dan menentukan konfigurasi kisi datar.

Observasi ini menyelidiki dampak koordinat  $z$  ujung elemen terhadap bentuk yang dihasilkan dan kisi datar akhir. Beberapa faktor, termasuk jarak antar elemen paralel, panjang elemen karakteristik, bentuk batas, beban yang diterapkan, tinggi punuk, dimensi penampang, dan lokasi pengangkatan, dapat memengaruhi proses pembentukan selama fase konstruksi pengangkatan. Berbagai bentuk kisi datar harus dianalisis untuk menemukan kisi datar optimal



untuk struktur cangkang kisi, yang dapat menjadi tugas yang mahal secara komputasi. Model ML berpotensi mengurangi waktu yang dibutuhkan untuk proses ini, dan algoritma ML yang dapat diinterpretasikan dapat digunakan untuk memilih kisi datar optimal, mengatasi kompleksitas tantangan ini.

### **Kinerja Struktural**

Prosedur desain mengintegrasikan kecerdasan manusia melalui serangkaian keputusan desain yang dibuat oleh perancang, dengan memanfaatkan pengalaman sebelumnya dan perbandingan fungsional. Desain berbantuan komputer membebaskan perancang dari tugas-tugas rutin, memungkinkan mereka untuk fokus pada aspek desain yang lebih kompleks. AI dalam ilmu komputer dapat sebagian menggantikan kecerdasan manusia dalam desain dengan menggabungkan sistem pakar dan teknologi AI ke dalam proses. Dalam desain struktural, inferensi simbolik dan komputasi numerik memainkan peran penting, terutama pada tahap awal. Keputusan desain kuantitatif dibuat untuk perkiraan ukuran elemen struktural, sementara keputusan kualitatif menentukan pemilihan jenis struktural.

Langkah-langkah paling penting dalam proses desain adalah menganalisis struktur dan mengukur kinerja strukturalnya. Pemanfaatan FEA untuk menilai kinerja struktural dan memeriksa batasan adalah metode yang populer. Namun, teknik alternatif baru dengan efisiensi yang lebih tinggi perlu dieksplorasi. Beberapa aktivitas analisis struktural yang intensif secara komputasi juga dapat memperoleh manfaat dari integrasi model ML, yang dapat membantu menghemat waktu dan tenaga dengan menyederhanakan perhitungan dan mengurangi beban komputasi secara keseluruhan.

### **Optimasi Struktural**

Optimasi struktural adalah prosedur terbalik di mana variabel dioptimalkan untuk menentukan bentuk optimal suatu struktur yang meminimalkan fungsi kebugaran. Bentuk ideal dalam ruang desain ditentukan berdasarkan satu atau beberapa tujuan, sambil memenuhi serangkaian persyaratan yang telah ditentukan sebelumnya seperti deformasi yang diizinkan. Ketika tujuan atau kendala baru muncul, metode optimasi struktural harus beradaptasi untuk mengatasinya. Metode ini dapat menghasilkan bentuk struktural melalui proses pencarian bentuk atau bentuk matematis. Ukuran kinerja struktural harus dipilih untuk mendorong proses optimasi. Definisi fungsi kebugaran melibatkan dua komponen kunci: pertama, perancang harus memprioritaskan kriteria kinerja yang penting bagi struktur dan menemukan cara untuk mengkuantifikasinya; kedua, model komputasi untuk mensimulasikan kinerja harus dikembangkan.

Meminimalkan tegangan dan perpindahan adalah dua tujuan penting yang harus ditangani sepanjang proses optimasi struktur gridshell. Selama fase optimasi, tujuan kinerja struktural perlu dievaluasi untuk beberapa desain. Model ML dapat secara signifikan meningkatkan proses ini dengan menghitung tujuan-tujuan ini secara langsung, mengurangi ketergantungan pada analisis elemen hingga (FEA) yang ekstensif. Dengan model ML, hanya beberapa analisis yang diperlukan yang menyederhanakan proses dan meningkatkan efisiensi. Akibatnya, insinyur dapat dengan cepat menemukan serangkaian desain optimal Pareto,



membantu mengidentifikasi dan memahami pertukaran antara tujuan yang saling bertentangan.

#### **1.4 TUJUAN: PENINGKATAN ML UNTUK DESAIN GRIDSHELL GFRP**

Dalam rekayasa struktural, penggunaan metode AI untuk analisis struktural telah mengalami implementasi yang signifikan selama beberapa dekade terakhir. Di antara berbagai teknik komputasi, beberapa metode ML telah digunakan untuk memprediksi kinerja struktural. Namun, hanya sedikit observasi tentang peningkatan desain struktural struktur gridshell elastis GFRP menggunakan model ML. Model ML saat ini masih membutuhkan peningkatan kinerja, dan aplikasinya dapat diperluas ke struktur gridshell elastis GFRP. Oleh karena itu, studi ini berfokus pada peningkatan metode ML, aplikasinya, dan kinerjanya untuk struktur gridshell elastis GFRP. Observasi ini bertujuan untuk mengoptimalkan dan meningkatkan desain struktural gridshell ini melalui algoritma ML, berupaya mengembangkan kerangka kerja yang efisien dan hemat waktu yang meningkatkan penerapan jenis struktur ini. Tujuan observasi spesifiknya adalah sebagai berikut:

1. Memperkenalkan kerangka kerja berbasis ML untuk memfasilitasi penerapan struktur gridshell elastis GFRP dalam berbagai proses desain dan optimasi.
2. Memprediksi deformasi dan momen lentur struktur gridshell elastis GFRP dengan menganalisis elemen diskrit dan menerapkan model ML secara cepat dan efisien.
3. Menetapkan metode pencarian bentuk untuk struktur gridshell elastis GFRP selama konstruksi pengangkatan menggunakan pendekatan ML yang dapat diinterpretasikan.
4. Mengusulkan model ML yang andal untuk memprediksi perilaku struktural struktur gridshell elastis GFRP dengan melakukan studi perbandingan pada berbagai metode ML.
5. Menyelidiki variabel dan tren paling signifikan dalam memprediksi kinerja struktural untuk meningkatkan pemahaman tentang interaksi antara variabel input dan output.
6. Menyajikan model optimasi multi-objektif untuk optimasi bentuk struktur gridshell elastis GFRP untuk mencapai bentuk optimal.

#### **1.5 KERANGKA DESAIN GRIDSHELL GFRP BERBASIS ML**

Buku ini menyajikan kerangka kerja desain struktural struktur cangkang kisi elastis GFRP menggunakan berbagai metode ML, termasuk LR, RR, KNN, DT, RF, AdaBoost, XGBoost, CatBoost, LightGBM, ANN, SVM, LSSVM, WLSSVM, PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM. Teknik-teknik ini diterapkan untuk meningkatkan desain struktural cangkang kisi melalui prediksi bentuk, pencarian bentuk, evaluasi kinerja struktural, dan optimasi bentuk. Untuk mencapai hal ini, beberapa set data dihasilkan melalui FEA menggunakan perangkat lunak ABAQUS, yang berfungsi sebagai dasar untuk melatih dan menguji algoritma ML. Selain itu, akurasi dan kemampuan analitis dari metode cerdas ini diselidiki, bertujuan untuk menyoroti bagaimana teknik ML dapat mengatasi masalah dunia nyata dan memperluas potensi struktur cangkang kisi.

Dalam buku ini, teori model elemen diskrit ditetapkan dan divalidasi menggunakan FEA. Selanjutnya, metode ML diterapkan untuk prediksi bentuk batang ramping. Setelah itu, algoritma ML digunakan untuk memprediksi bentuk struktur gridshell dengan mempertimbangkan deformasi elemen diskrit. Kebaruan pendekatan ini terletak pada penggunaan karakteristik elemen diskrit untuk mempersiapkan dataset daripada menganalisis seluruh struktur, yang secara komputasi mahal. Kubah barel dan gridshell simetris biaxial dianalisis dengan metode ML yang disajikan, dengan mempertimbangkan deformasi geometris yang signifikan.

Pendekatan pencarian bentuk baru berdasarkan teknik ML yang dapat diinterpretasikan kemudian dikembangkan, dengan mempertimbangkan proses konstruksi pengangkatan untuk mencapai kisi datar yang optimal. Model ML juga digunakan untuk mempelajari perilaku struktural struktur gridshell elastis GFRP, dan studi perbandingan beberapa model ML dilakukan untuk memprediksi tegangan maksimum dan rasio perpindahan terhadap berat sendiri. Metode ML yang dapat diinterpretasikan diterapkan untuk memahami pengaruh setiap parameter input pada faktor output, dan pendekatan optimasi bentuk baru dikembangkan. Model optimasi hibrida yang diusulkan, yang disebut sebagai metode WL $\epsilon$ TSVM-MOPSO-TOPSIS, digunakan untuk menentukan bentuk optimal struktur gridshell. Metodologi Taguchi digunakan untuk menyempurnakan variabel dalam algoritma optimasi swarm partikel multi-objektif (MOPSO) dalam pendekatan ini.

## **1.6 STRUKTUR BUKU: TINJAUAN HINGGA OPTIMASI GRIDSHELL**

Bab-bab dalam buku ini disusun sebagai berikut:

1. Bab 2 menyajikan tinjauan komprehensif tentang definisi gridshell elastis, material GFRP, elemen gridshell, berbagai desain, dan teknik pencarian bentuk, serta metode konstruksi. Selain itu, peluang dan tantangan yang terkait dengan gridshell GFRP dibahas secara detail. Bab ini juga memperkenalkan beberapa algoritma ML, termasuk LR, RR, KNN, DT, RF, AdaBoost, XGBoost, CatBoost, LightGBM, ANN, SVM, LSSVM, WLSSVM, PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM. Selain itu, pendekatan ML yang dapat diinterpretasikan dan beberapa algoritma yang bertujuan untuk meningkatkan efisiensi model ML dibahas.
2. Bab 3 menyajikan teori analitik model elemen diskrit dan menjelaskan interaksi antar anggota, diikuti dengan validasi menggunakan FEA. Selanjutnya, model ML diterapkan untuk prediksi bentuk batang ramping.
3. Bab 4 menyajikan metode konstruksi pengangkatan, prediksi deformasi elemen dan momen lentur pada struktur gridshell elastis, dan proses prediksi bentuk berdasarkan model ML. Selanjutnya, dua contoh numerik kubah barel dan struktur gridshell simetris biaxial dianalisis.
4. Bab 5 berfokus pada pencarian bentuk cangkang grid GFRP selama proses konstruksi pengangkatan menggunakan pendekatan ML yang dapat diinterpretasikan. Bab ini menyajikan prinsip-prinsip prosedur pencarian bentuk dan tahapan proses konstruksi. Sebuah contoh numerik diberikan dan efisiensi proses pencarian bentuk diverifikasi.

5. Bab 6 mencakup analisis struktural struktur cangkang grid elastis GFRP dan interpretasi pendekatan ML. Sepuluh model ML dibandingkan untuk mengidentifikasi model yang optimal, dan model prediksi dijelaskan menggunakan plot ketergantungan parsial (PDP), efek lokal terakumulasi (ALE), dan penjelasan aditif Shapley (SHAP).
6. Bab 7 mencakup desain parametrik cangkang grid, persiapan dataset, dan FEA. Selanjutnya, studi perbandingan dilakukan untuk mengidentifikasi model ML yang optimal, dengan menggabungkan validasi silang K-fold (CV), metode Taguchi, dan teknik untuk preferensi urutan berdasarkan kesamaan dengan solusi ideal (TOPSIS) selama proses tersebut. Selain itu, dikembangkan pula proses optimasi hibrida spesifik.
7. Bab 8 menyajikan kesimpulan yang diambil dari hasil observasi dan menyoroiti peluang observasi di masa mendatang.



## **BAB 2**

# **STRUKTUR GRIDSHELL GFRP DAN ALGORITMA PEMBELAJARAN MESIN**

### **2.1 TINJAUAN GRIDSHELL DAN APLIKASI ML**

Struktur gridshell adalah atap kisi ringan lengkung ganda dengan bentang lebar. Gridshell awalnya dibangun dari kisi datar tanpa kekakuan geser bidang, memungkinkan kisi untuk dideformasi tegak lurus terhadap bidangnya untuk menciptakan permukaan lengkung ganda. Setelah diberi penyangga, perilaku struktural gridshell mencerminkan perilaku struktur cangkang tradisional. Kekuatan gridshell berasal dari bentuk lengkung gandanya yang berkontribusi pada stabilitas keseluruhan dan kapasitas menahan bebannya. Studi komprehensif tentang gridshell telah dilakukan oleh Bouhaya dan Hernandez yang memberikan wawasan berharga tentang desain dan kinerjanya.

Struktur gridshell menawarkan beberapa manfaat, termasuk penggunaan material yang minimal, desain yang ringan, kemampuan untuk menciptakan struktur bentang lebar, peningkatan efisiensi struktural, potensi konstruksi dan transportasi yang cepat dan hemat biaya, penciptaan ruang tanpa kolom, keberlanjutan, dan kemudahan pembongkaran dan daur ulang. Untuk mempertahankan dan memperluas penerapan gridshell, penting untuk mempertimbangkan analisis tingkat lanjut, pengembangan metode komputer untuk mensimulasikan gridshell yang kompleks, teknik baru untuk pencarian bentuk dan proses konstruksi, penerapan algoritma pembelajaran mesin (ML) dalam proses desain dan optimasi, dan mengeksplorasi cara untuk menciptakan struktur gridshell permanen alih-alih yang sementara.

Struktur spasial memiliki potensi besar untuk optimasi desain struktural, meskipun sudah menjadi salah satu sistem yang paling efisien dan menunjukkan perilaku struktural yang kompleks. Dalam desain struktur spasial, ML dapat sangat menguntungkan karena kemampuannya untuk mendeteksi hubungan yang rumit antara fitur input dan output dalam kumpulan data yang besar. Mirra dan Pugnale, misalnya, membandingkan ruang desain yang dihasilkan oleh kecerdasan buatan (AI) yang diproduksi oleh model auto-encoder variasional dengan ruang desain yang dibuat melalui deskripsi fitur yang dirancang manusia secara eksplisit. Demikian pula, Zheng et al. mengeksplorasi hubungan mendasar antara bentuk dan gaya dalam struktur cangkang menggunakan statika grafis. Mereka melatih algoritma jaringan saraf untuk memprediksi bagaimana metrik kinerja konstruksi dan struktural berhubungan dengan aturan subdivisi.

Setelah hubungan antara fitur input dan output diperoleh melalui model ML, proses optimasi konfigurasi struktural menjadi lebih mudah, seperti yang dicatat dalam observasi terbaru. Namun, otomatisasi penuh prosedur optimasi, di mana model ML secara independen memilih variabel desain, tetap menjadi tantangan. Kesulitan ini muncul dari kebutuhan agar variabel-variabel ini ada dalam ruang berdimensi rendah yang dapat dioptimalkan tanpa



mengorbankan daya representasinya. Xue dkk. menghadapi tantangan ini selama optimasi desain material. Sebagai tanggapan, Danhaive dan Mueller mengusulkan penggunaan auto-encoder variasional sebagai alternatif untuk melatih model dua dimensi (2D) yang bertujuan untuk mendesain struktur atap bentang panjang. Sementara itu, Preisinger dan Heimrath menggunakan 36 faktor desain dalam optimasi penampang elemen rangka, menawarkan kontrol yang lebih besar atas trade-off kinerja dibandingkan dengan model yang menggabungkan optimasi dengan pencarian tak terarah.

ML merupakan cabang penting dari AI yang berfokus pada pengembangan model yang mampu belajar dari data dan menghasilkan estimasi. Algoritma berbasis ML dapat bersifat deskriptif atau prediktif, mengekstrak informasi berharga dari sampel data. Teknologi ini menemukan aplikasi di berbagai bidang, seperti ilmu komputer, pasar keuangan, probabilitas dan statistik, teori kontrol, dan teori informasi. Pada dasarnya, ML mencakup teknik untuk secara otomatis mengidentifikasi pola dalam data, yang kemudian dapat digunakan untuk membuat model prediksi, mendukung pengambilan keputusan dalam skenario yang tidak pasti. Dalam rekayasa struktur, kinerja gridshell biasanya dievaluasi melalui analisis elemen hingga (FEA), suatu proses yang dikenal memakan waktu. Untuk meningkatkan efisiensi analisis struktural, algoritma ML dapat digunakan untuk memprediksi perilaku struktural gridshell elastis, menawarkan alternatif yang lebih cepat daripada metode konvensional.

## **2.2 STRUKTUR GRIDSHELL ELASTIS GFRP**

Keunggulan utama struktur gridshell elastis polimer yang diperkuat serat kaca (GFRP) terletak pada metode konstruksinya yang efisien, yang hemat waktu dan biaya. Gridshell ini memiliki anggota yang melengkung dan ramping yang berkontribusi pada daya tarik estetikanya, menghasilkan struktur yang elegan dan menarik secara visual. Selain itu, struktur ini mendukung keberlanjutan karena jumlah material yang dibutuhkan untuk konstruksinya minimal. Gambar 2.1 mengilustrasikan kriteria desain untuk gridshell elastis, menyoroti keseimbangan kritis antara bentuk, fungsionalitas, dan efisiensi sumber daya dalam desainnya.

### **Struktur Gridshell Elastis**

Gridshell elastis adalah atap kisi ringan yang memiliki bentang lebar dan kelengkungan ganda, dibangun dari kisi datar yang tidak memiliki kekakuan geser. Kisi datar ini dapat dideformasi oleh beban yang bekerja tegak lurus terhadap bidangnya, memungkinkan struktur untuk mencapai bentuk yang diinginkan. Karena kepadatan material yang rendah dan deformasi signifikan yang dialami selama konstruksi, tegangan total pada balok ramping cangkang kisi elastis GFRP sebagian besar disebabkan oleh lentur. Tegangan ini dapat dihitung menggunakan Persamaan (2.1), sebagai berikut:

$$\sigma \approx \frac{M}{I/r} = E \cdot \frac{r}{R} \quad (2.1)$$



**Gambar 2.1** Kriteria desain untuk cangkang kisi elastis.

di mana  $\sigma$ ,  $M$ ,  $E$ ,  $r$ ,  $I$ , dan  $R$  masing-masing mewakili tegangan total, momen lentur, modulus Young longitudinal, jari-jari luar penampang, momen inersia penampang, dan jari-jari kelengkungan balok. Parameter-parameter ini memainkan peran penting dalam menentukan kekuatan dan perilaku material di bawah pembebanan. Secara khusus, untuk material GFRP, kelengkungan balok minimal dibatasi oleh nilai yang diizinkan untuk memastikan integritas material. Seperti yang ditunjukkan pada Persamaan (2.2), bentuk cangkang kisi elastis dapat dioptimalkan pada tahap desain skematis dengan mempertimbangkan faktor-faktor ini, memastikan bahwa kelengkungan balok tetap berada dalam batas yang diizinkan untuk keselamatan dan efisiensi struktural.

$$R_{min} > \frac{E \cdot r}{\sigma_{max}} \quad (2.2)$$

di mana  $R_{min}$  dan  $\sigma_{max}$  masing-masing mewakili radius minimum kelengkungan balok dan tegangan maksimum.

### **Polimer yang Diperkuat Serat Kaca**

Beberapa observasi telah dilakukan untuk mengidentifikasi material terbaik untuk cangkang kisi elastis. Douthe dkk. mempelajari material baru yang lebih unggul daripada kayu untuk membangun cangkang kisi elastis. Kotelnikova-Weiler menyelidiki perilaku jangka panjang batang GFRP pultruded di bawah tegangan torsi dan lentur. Dibandingkan dengan kayu, profil GFRP menunjukkan regangan batas elastis yang lebih tinggi sebesar 1,5% dan batas kekuatan yang lebih tinggi, melebihi 400 MPa. Selain itu, karena ada hubungan linier antara beban tekuk dan modulus Young ( $E$ ), beban tekuk yang lebih tinggi dari cangkang kisi yang terbuat dari GFRP dapat dikaitkan dengan nilai  $E$  yang lebih tinggi, yaitu 25–30 GPa. Selain itu, GFRP menunjukkan ketahanan tinggi di lingkungan yang agresif seperti paparan radiasi UV, air laut, dan udara asam.

### **Sambungan Baut**

Terdapat tiga jenis konektor yang digunakan pada gridshell elastis GFRP: konektor ujung-ke-ujung, konektor putar, dan jangkar tanah, seperti yang ditunjukkan pada Gambar 2.2. Konektor ujung-ke-ujung digunakan untuk menyambung profil GFRP, menciptakan balok yang lebih panjang. Konektor putar, di sisi lain, menghubungkan dua balok pada lapisan yang berbeda, memungkinkan rotasi bidang sambil mencegah translasi dan rotasi di luar bidang. Terakhir, jangkar tanah menghubungkan ujung-ujung anggota ke tanah setelah proses pemasangan, seperti yang dirujuk dalam observasi.

### **Penyangga**


Penyangga merupakan langkah penting dalam konstruksi gridshell, karena gridshell tidak memiliki ketahanan geser bidang sebelum diberi penyangga. Dalam kasus cangkang grid elastis GFRP, penguatan umumnya dicapai dengan menambahkan lapisan balok diagonal ke struktur grid dua lapis. Modifikasi ini mengubah pola grid dari segi empat fleksibel menjadi serangkaian segitiga kaku, sehingga memberikan kekakuan geser bidang dan memungkinkan struktur berperilaku sebagai cangkang. Observasi telah menunjukkan bahwa setelah penguatan, kekakuan struktur dapat meningkat hingga 20 kali lipat dibandingkan dengan keadaan sebelum penguatan, memungkinkan struktur untuk menunjukkan sifat mekanik penuhnya.

## **2.3 DESAIN CANGKANG GRID ELASTIS GFRP**

Desain cangkang grid elastis GFRP terutama berfokus pada dua aspek: desain geometri dan analisis struktural. Selama fase desain geometri, sangat penting untuk menentukan pola grid dari cangkang grid yang telah dibangun dan grid datar dua lapis yang sesuai. Secara historis, model fisik sering digunakan untuk desain geometri cangkang grid elastis, khususnya pada abad terakhir. Kontribusi signifikan dalam bidang ini bermula pada tahun 1676 ketika Robert Hooke menunjukkan bahwa konfigurasi stabil sebuah lengkungan dapat dicapai dengan membalikkan bentuk rantai gantung di bawah kondisi pembebanan yang sama. Dalam perkembangan yang lebih baru, Xiang et al. memperkenalkan metode inovatif yang



menggabungkan analisis pencarian bentuk dengan prosedur konstruksi pengangkatan untuk mendesain dan menganalisis cangkang grid GFRP. Dalam studi selanjutnya, mereka lebih menyempurnakan teknik ini, mengembangkan pendekatan pencarian bentuk untuk memperkirakan momen lentur, gaya nodal, dan deformasi pada cangkang grid simetris biaxial.



**Gambar 2.2** (a) Rakitan yang digunakan untuk menyambungkan dua balok; (b) konektor putar; (c) jangkar pin untuk balok.

### **Desain Geometri**

Dalam desain geometri cangkang grid elastis GFRP, pendekatan desain yang ada dapat diklasifikasikan menjadi dua kategori berdasarkan apakah mereka mempertimbangkan keseimbangan statis anggota cangkang grid selama penentuan pola grid atau tidak. Hernandez memperkenalkan tiga metode untuk mendesain cangkang grid elastis: metode kompas, algoritma genetik, dan prinsip variasi. Metode kompas adalah pendekatan yang efisien untuk mendesain struktur cangkang grid elastis. Proses dimulai dengan menghasilkan dua kurva pada permukaan yang mendefinisikan garis luar empat segi empat. Setiap segi empat kemudian dibagi lagi menggunakan kompas dengan panjang yang konsisten. Akhirnya, dua bagian setengah kuadran berurutan di-mesh, dengan mempertahankan panjang kompas yang sama di seluruh bagian.

Memilih metode yang tepat untuk pembentukan bentuk dipengaruhi oleh berbagai faktor, termasuk sifat material, jenis struktur, batasan tegangan dan perpindahan terhadap nilai absolut, kebutuhan untuk menghindari tekuk dan creep yang berlebihan, serta persyaratan dan biaya konstruksi. Pertimbangan tambahan meliputi memastikan masa pakai yang wajar, mencapai desain yang estetik, dan mematuhi kondisi batas dan kasus beban. Hernandez mengusulkan beberapa pendekatan pencarian bentuk, seperti menggunakan grid datar yang telah ditentukan sebelumnya, pegas pembentuk vertikal, gaya pembentuk vertikal, dan metode energi regangan terkecil.

### **Analisis Struktural**

Setelah proses pencarian bentuk, perilaku struktural dari gridshell yang dihasilkan harus dianalisis di bawah beban eksternal. Karena tidak adanya alat desain digital khusus untuk

gridshell elastis, perancang dan peneliti sering mengandalkan perangkat lunak analisis komersial tujuan umum. Perangkat lunak ini biasanya menggunakan FEA dan metode relaksasi dinamis. FEA, yang diakui sebagai metode yang paling banyak diadopsi untuk analisis struktural, terintegrasi dengan mulus dalam alur kerja pemodelan informasi bangunan (BIM), memungkinkan simulasi dan evaluasi kinerja yang akurat. Penggabungan BIM meningkatkan kolaborasi dan menyederhanakan pertukaran data antara desain dan analisis, mendorong pengambilan keputusan yang lebih efisien baik dalam fase desain maupun observasi.

### **Kode dan Standar Desain**

Dalam bidang konstruksi bangunan yang menggunakan material komposit, tiga standar utama secara luas dianggap sebagai referensi: (1) Kode dan Buku Pegangan Desain Eurocomp; (2) Panduan untuk Desain dan Konstruksi Struktur yang terbuat dari Elemen Pultruded FRP; dan (3) Komposit untuk Konstruksi: Desain Struktural dengan Material FRP. Struktur yang terbuat dari elemen GFRP, seperti cangkang kisi elastis GFRP, dapat dirancang dengan merujuk pada ketiga sumber ini.

## **2.4 PROSES PEMASANGAN**

Proses pemasangan cangkang kisi elastis sangat penting karena tegangan lentur tinggi yang dihasilkan oleh elemen lengkung selama konstruksi, yang menyoroti peran pentingnya dalam memastikan integritas struktural. Alessandro dan Alberto melakukan tinjauan terhadap metode konstruksi untuk struktur gridshell, menguraikan fitur khas dan kekurangan inherennya. Quinn dan Gengnagel dalam karya mereka mengusulkan lima metode pemasangan untuk struktur gridshell elastis: tarik ke atas, dorong ke atas, turunkan perlahan, kembangkan, dan dengan batasan.

## **2.5 PELUANG INOVASI CANGKANG KISI GFRP**

Struktur cangkang kisi elastis GFRP merupakan struktur rumit yang menghadirkan beberapa peluang inovasi, dan para peneliti semakin fokus pada pengembangan investigasi mereka di bidang ini. Keunggulan cangkang kisi elastis GFRP meliputi fleksibilitas geometrisnya yang memungkinkan berbagai konfigurasi desain, dan waktu konstruksinya yang singkat, sehingga memungkinkan penyelesaian proyek yang lebih cepat. Selain itu, struktur ringan ini menawarkan manfaat lingkungan yang signifikan, berkontribusi pada praktik pembangunan yang lebih berkelanjutan. Bagian ini membahas peluang-peluang tersebut, menyoroti potensi cangkang kisi elastis GFRP untuk merevolusi metodologi konstruksi modern.


### **Fleksibilitas Geometris**

Berkat deformabilitas dan kekuatan material GFRP yang luar biasa, dikombinasikan dengan konektor putar yang inovatif, kisi datar dapat mengalami deformasi yang signifikan untuk menciptakan permukaan lengkung ganda. Cangkang kisi elastis GFRP menawarkan efisiensi struktural yang luar biasa, menggunakan lebih sedikit material untuk bentang yang luas. Selain itu, kepadatan rendah material GFRP menjadikan struktur gridshell elastis sangat ringan. Seperti yang diilustrasikan pada Gambar 2.3, bagian-bagian cangkang yang terdiri dari material substansial dapat secara efektif digantikan dengan modul gridshell yang mengurangi

penggunaan material. Lebih lanjut, celah antara tabung GFRP memberikan beberapa peluang untuk penetrasi bangunan dan pencahayaan alami.

### **Konstruksi Cepat**

Dalam industri konstruksi, durasi konstruksi yang lebih lama dapat secara signifikan meningkatkan biaya karena pengeluaran tenaga kerja dan peralatan. Namun, prosedur konstruksi cepat gridshell secara efektif mengurangi pengeluaran ini selama fase konstruksi. Bentuk akhir gridshell berasal dari grid datar awal yang menawarkan beberapa keuntungan, termasuk profil standar, simpul sambungan standar, dan geometri planar. Fitur-fitur ini menyederhanakan proses konstruksi, memungkinkan gridshell elastis GFRP untuk meminimalkan waktu konstruksi, dengan perakitan di lokasi yang sangat cepat. Oleh karena itu, struktur cangkang jaring sangat cocok untuk operasi penyelamatan dalam keadaan darurat, seperti bencana alam.



**Gambar 2.3** Aksi struktural pada: (a) cangkang kontinu dan (b) elemen cangkang jaring.

### **Struktur Ringan**

Struktur ringan sangat penting untuk masa depan, untuk memenuhi kebutuhan sosial, ekologis, dan budaya. Salah satu contoh yang menonjol adalah gridshell, cangkang lengkung ganda berbentuk bebas yang dibangun dari jaring seperti grid yang dirancang untuk menopang beban melalui resistensi bentuk dan konfigurasi gridnya. Jenis struktur ini, yang dikenal sebagai struktur ringan aktif bentuk, menunjukkan efisiensi yang luar biasa karena penggunaan material ringan yang dikombinasikan dengan kekuatan tinggi. Akibatnya, gridshell dapat dengan mudah dibengkokkan dan dipelintir, memaksimalkan efisiensi material. Berat sendiri biasanya berkisar antara  $5 \text{ kg/m}^2$  hingga  $20 \text{ kg/m}^2$ , memastikan bahwa struktur ini tetap ringan sambil mempertahankan integritas strukturalnya.

### **Keuntungan Lingkungan**

Frei Otto mendefinisikan gridshell sebagai struktur yang menggunakan material minimal untuk mengurangi dampak lingkungan sekaligus mendorong keberlanjutan sosial dan lingkungan. Struktur cangkang jaring elastis GFRP menawarkan keuntungan dalam menciptakan ruang yang luas dan bebas kolom dengan proses konstruksi yang cepat dan hemat biaya, sehingga sangat cocok untuk situasi krisis. Terdapat peningkatan permintaan global untuk tempat perlindungan besar guna menampung pertemuan keagamaan, pemulihan sosial, dan perawatan medis di daerah pengungsi atau daerah yang terkena bencana. Seiring

meningkatnya permintaan akan struktur berkelanjutan, salah satu strategi yang efektif adalah memilih material dan sistem berdasarkan penilaian siklus hidup dan dampak lingkungan. Cangkang jaring elastis GFRP menonjol sebagai solusi yang sangat baik, karena proses pembuatannya lebih ramah lingkungan dibandingkan dengan material konstruksi tradisional seperti baja dan beton.

## **2.6 TANTANGAN CANGKANG JARING GFRP**

Saat ini, cangkang jaring elastis GFRP, yang dikenal karena sifatnya yang ringan dan kemampuannya untuk menutupi bentang yang besar, telah mengalami adopsi yang terbatas di masyarakat karena beberapa tantangan. Ini termasuk biaya tinggi, variabilitas, dan keterbatasan dalam prosedur pembuatan, serta masalah yang terkait dengan metodologi desain dan alur kerja digital. Selain itu, proses desain dan optimasi menghadirkan hambatan yang harus diatasi. Namun, jelas bahwa dengan mengatasi hambatan-hambatan ini, struktur cangkang elastis GFRP memiliki potensi signifikan untuk aplikasi yang lebih luas sebagai struktur sementara dan permanen dalam industri bangunan.

### **Faktor Biaya Cangkang GFRP**

Biaya struktur cangkang elastis GFRP dipengaruhi oleh berbagai faktor, termasuk biaya yang terkait dengan fase desain, material, elemen sambungan, proses pemasangan, penguat, tenaga kerja, dan peralatan lain yang diperlukan. Keunggulan ekonomis dari cangkang berasal dari kemampuannya untuk menutupi ruang yang luas dengan jumlah material yang sedikit, proses konstruksi yang cepat, transportasi yang hemat biaya, dan perakitan berteknologi rendah untuk masing-masing elemen. Khususnya dalam kasus struktur atap, cangkang muncul sebagai salah satu pilihan yang paling hemat biaya karena elemen dan sambungannya yang minimal, yang menyebabkan pengurangan jumlah tenaga kerja yang dibutuhkan. Mengingat bahwa biaya sumber daya manusia biasanya mencapai 15–50% dari total biaya konstruksi, penurunan jumlah tenaga kerja secara signifikan berkontribusi pada penurunan biaya konstruksi secara keseluruhan.

### **Variabilitas dan Keterbatasan Proses Pembuatan**

Struktur gridshell menawarkan keuntungan yang signifikan dalam pembuatan karena desainnya, yang melibatkan bentuk lengkung ganda yang dibangun dari grid datar elemen ramping. Permukaan datar awal ini menyederhanakan proses penyambungan dan pembuatan, sehingga lebih mudah diakses dibandingkan dengan struktur tiga dimensi. Namun, tantangan signifikan tetap ada dalam menentukan posisi akhir sambungan, masalah yang belum terselesaikan.

Para perancang sangat memperhatikan kemudahan proses pembuatan, yang sangat penting untuk mencapai bentuk yang diinginkan. Selain itu, tidak adanya pedoman dan praktik konstruksi standar menimbulkan tantangan besar bagi struktur gridshell. Untuk mengatasi masalah ini, observasi lebih lanjut sangat penting untuk menetapkan instruksi yang jelas dan standar desain yang sesuai. Kurangnya standar tersebut dapat menyebabkan kerusakan selama pembuatan, yang menekankan perlunya protokol yang lebih baik. Metode pembelajaran mesin dapat memainkan peran penting dalam konteks ini, karena metode ini

mengungkap informasi tersembunyi mengenai kinerja struktur cangkang jaring dengan menganalisis dampak berbagai kerusakan.

### **Metodologi Desain dan Alur Kerja Digital**

Sangat penting untuk memajukan metode komputasi untuk memodelkan struktur gridshell tiga dimensi yang rumit untuk mempertahankan pemanfaatan gridshell yang efektif. Ini termasuk penerapan algoritma ML selama fase desain dan pertimbangan teknik inovatif untuk pencarian bentuk. Model numerik yang disempurnakan dengan solver FE digital diperlukan untuk secara akurat mengekstrapolasi tegangan membran dan tegangan nodal selama proses pemasangan. Data yang dihasilkan dari platform ini berkontribusi pada pengembangan kumpulan data yang andal yang cocok untuk model ML. Algoritma ML berfungsi sebagai alat yang ampuh untuk membuat model prediktif perilaku struktural.

### **Desain dan Optimasi Struktur**

Optimasi gridshell memiliki tujuan ganda yaitu meminimalkan tegangan selama proses pemasangan dan meningkatkan ketahanan terhadap beban eksternal. Optimasi ini sangat penting dalam fase desain dan pencarian bentuk, di mana upaya diarahkan untuk mengurangi kelengkungan grid, mengoptimalkan arah balok, menghindari kelemahan pada sambungan nodal elemen kontinu, dan memfasilitasi metode penguatan yang lebih efektif. Selain itu, integrasi algoritma ML untuk memprediksi perilaku struktural selama proses optimasi telah terbukti bermanfaat, secara signifikan mengurangi waktu yang dibutuhkan untuk optimasi dan meningkatkan efisiensi komputasi.

## **2.7 KECERDASAN BUATAN**

AI mengacu pada kemampuan sistem untuk mereplikasi kecerdasan manusia dan fungsi kognitif, yang mencakup berbagai kemampuan seperti kecerdasan umum, robotika, persepsi, pemrosesan bahasa alami, pembelajaran, perencanaan otomatis, penalaran, dan representasi pengetahuan, yang merupakan tujuan utama observasi AI. ML, sub-bidang AI, berfokus pada pengembangan model yang mengenali pola, menekankan estimasi berdasarkan properti yang diketahui. Dalam domain ini, pembelajaran mendalam (DL) menonjol sebagai area khusus ML yang berkonsentrasi pada pelatihan representasi dan fitur.

## **2.8 PEMBELAJARAN MESIN**

ML adalah metode yang ampuh untuk analisis dan pemodelan data di berbagai aplikasi. Algoritma tradisional menghasilkan output dengan mempertimbangkan beberapa faktor input dan menerapkan logika yang telah ditentukan sebelumnya dalam bentuk kode. Namun, algoritma ML mengambil faktor input dan output dan menghasilkan logikanya sendiri, yang kemudian dapat diterapkan pada input baru untuk menghasilkan output yang sesuai. Alasan mengapa ML mengungguli metode tradisional adalah sebagai berikut:

1. ML dapat mengenali pola yang terlalu kompleks untuk dideteksi manusia.
2. ML membuat prediksi berdasarkan kumpulan data yang jauh lebih besar dibandingkan dengan metode tradisional.
3. Opini subjektif dan emosi manusia memiliki sedikit atau tidak ada pengaruh pada ML.



4. ML dapat beradaptasi dengan cepat terhadap perubahan.
5. ML lebih sulit dimanipulasi daripada metode tradisional.

Membangun model yang tepat melibatkan tahapan berikut: mengumpulkan sampel, melakukan pra-pemrosesan data, membangun, melatih, dan mengevaluasi model, mengembangkan model lebih lanjut, dan menghasilkan prediksi. Algoritma ML dapat diklasifikasikan menjadi pembelajaran terawasi (*supervised learning*), pembelajaran tak terawasi (*unsupervised learning*), dan pembelajaran penguatan (*reinforcement learning*).

## 2.9 MODEL PEMBELAJARAN MESIN

Semua algoritma ML yang disajikan dalam bab ini dapat digunakan untuk masalah regresi, termasuk *regresi linier* (LR), *regresi ridge* (RR), *K-nearest neighbor* (KNN), pohon keputusan (DT), *random forest* (RF), XGBoost, AdaBoost, CatBoost, LightGBM, jaringan saraf tiruan (ANN), mesin vektor pendukung kuadrat terkecil berbobot (WLSSVM), optimasi swarm partikel-LSSVM (PSO-LSSVM), parametric-insensitive nonparallel (PIN)-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM. Deskripsi singkat tentang algoritma ini diusulkan, dan penjelasan yang lebih komprehensif dapat ditemukan dalam literatur yang dirujuk.

### Regresi Linier

LR adalah pendekatan ML terawasi yang mengidentifikasi hubungan linier antara variabel dependen dan independen. Ini adalah salah satu teknik paling sederhana untuk menentukan ketergantungan variabel keluaran pada fitur masukan. Koefisien optimal untuk parameter diperoleh dengan meminimalkan kesalahan kuadrat terkecil antara nilai aktual dan nilai estimasi. Keluaran dari regresi linier (LR) adalah kombinasi linier dari variabel-variabel tersebut, seperti yang ditunjukkan di bawah ini:

$$f(X) = \beta_0 + \sum_{i=1}^M X_i \beta_i \quad (2.3)$$

di mana  $\beta_0$  dan  $\beta_i$  masing-masing mewakili intersep dan koefisien regresi;  $M$  adalah jumlah parameter. Koefisien regresi dihitung sebagai berikut:

$$\beta_{LR} = \underset{\beta}{\operatorname{arg\,min}} \left[ \sum_{j=1}^N (y_j - f(x_j))^2 \right] \quad (2.4)$$

di mana  $N$  adalah jumlah instance dan  $y_j$  menunjukkan output target.

### Regresi Ridge

RR sebanding dengan LR kecuali bahwa ia mengurangi varians model LR. Sebagian besar pendekatan ML memiliki trade-off bias-variens. RR adalah pendekatan populer untuk mengecilkan koefisien dengan meminimalkan jumlah kuadrat. Meminimalkan fungsi biaya yang diberi penalti menghitung koefisien ridge sebagai berikut:

$$\beta_{Ridge} = \arg \min_{\beta} \sum_{j=1}^N \left( y_j - \beta_0 - \sum_{i=1}^M X_{ji} \beta_i \right)^2 + \lambda \sum_{i=1}^M \beta_i^2 \quad (2.5)$$

di mana  $\lambda$  menentukan pengurangan koefisien. Koefisien RR mendekati nol seiring meningkatnya  $\lambda$ .

**K-Nearest Terdekat**

Variabel keluaran diprediksi oleh KNN sebagai rata-rata dari beberapa nilai di sekitarnya, di mana  $k$  mengacu pada jumlah tetangga yang digunakan. Konsep penting dari KNN adalah bahwa KNN memberikan bobot lebih besar pada  $K$  sampel terdekat yang lebih dekat ke titik data baru  $x$  dalam dataset pelatihan. Probabilitas bersyarat dari  $x$  dapat dihitung dengan rumus berikut:

$$P(Y = m|X = x) = \frac{1}{K} \sum_{i \in N_k} I(y_i = m) \quad (2.6)$$

di mana  $I(y_i = m)$  adalah parameter yang berfungsi sebagai indikator; jika observasi tertentu termasuk dalam tag ke- $m$ , maka akan mengembalikan 1; jika tidak, akan mengembalikan 0;  $N_k$  adalah jumlah instance.

**Pohon Keputusan**

DT adalah pendekatan ML terawasi yang dapat digunakan untuk model regresi. Metode ini meningkatkan model prediktif dalam grafik seperti pohon. Struktur pohon mencakup parameter input dari dataset sebagai node internal, aturan keputusan sebagai cabang, dan output sebagai node daun. Pohon regresi adalah serangkaian pendekatan ML yang membuat model estimasi dengan membagi ruang fitur menjadi ruang berdimensi tinggi. Dengan membagi ruang fitur menjadi  $D$  area,  $R_1, \dots, R_D$ , masalah regresi dapat dijelaskan sebagai:

$$f(x) = \sum_{d=1}^D c_d I(x \in R_d) \quad (2.7)$$

di mana  $c_d$  menunjukkan rata-rata dari pengamatan.

**Random Forest**

RF adalah teknik ML yang terdiri dari banyak pohon keputusan. Brieman mengembangkan RF, yang menggabungkan pendekatan bagging dengan strategi pemilihan parameter input acak. Pendekatan bagging menciptakan pohon individual dengan mengganti dataset pelatihan dengan sampel acak (sampel bootstrap). Teknik ini mengontrol overfitting dengan mengurangi modifikasi yang diterapkan pada setiap pohon. Lebih lanjut, alih-alih memilih semua parameter, subset acak dari parameter tersebut digunakan. Secara khusus, RF adalah varian yang ditingkatkan dari pendekatan bagging. Output yang diperkirakan diperoleh dengan merata-ratakan hasil dari setiap DT sebagai berikut:

$$Y = \frac{1}{B} \sum_{j=1}^b Y_b(X') \quad (2.8)$$

di mana  $B$  mengacu pada jumlah DT;  $Y_b$  menunjukkan setiap DT;  $X'$  adalah instance yang tidak diketahui.

### **AdaBoost**

Model AdaBoost menciptakan pembelajar yang kuat dari serangkaian pembelajar lemah untuk meningkatkan kinerja model yang diestimasi. Dalam algoritma AdaBoost, instance yang diestimasi secara tidak benar diberi bobot yang lebih tinggi pada tahap sebelumnya. Kinerja model kemudian ditingkatkan dengan meminimalkan kegagalan pada tahap selanjutnya. AdaBoost dimulai dengan bobot yang identik dan mengevaluasi kesalahan kuadrat rata-rata estimasi, memberikan bobot yang lebih besar kepada mereka yang memiliki kegagalan terbesar dan mengulangi prosedur tersebut hingga hasilnya konvergen.

### **XGBoost**

XGBoost adalah metode boosting di mana pembelajar lemah secara iteratif diberi bobot yang lebih tinggi. Idennya adalah untuk mengintegrasikan pembelajar lemah untuk membuat perkiraan yang lebih akurat. Gradient boosting pertama kali diperkenalkan oleh Chen et al., yang melakukan model regresi menggunakan vektor gradien arah dari fungsi misfit yang sebanding dengan teknik gradient-descent. Gradient boosting menggunakan versi pohon paralel yang dikenal sebagai XGBoost. Dalam metode ini, faktor-faktor dimodifikasi secara iteratif untuk mengoptimalkan fungsi tujuan dengan mengurangi residual dari langkah sebelumnya. Untuk menghindari overfitting, pendekatan XGBoost menambahkan regularisasi pada fungsi tujuan dan fungsi kerugian.

### **CatBoost**

CatBoost memperkenalkan pendekatan baru untuk gradient boosting dengan secara khusus berfokus pada parameter input kategorikal. Metode ini memanfaatkan DT simetris, yang secara signifikan meningkatkan kecepatan inferensi saat menggunakan model pembelajaran lemah yang telah dilatih sebelumnya. CatBoost dirancang untuk menangani data bising dengan hubungan yang kompleks dan karakteristik yang beragam, memastikan kinerja yang lebih baik. Algoritma ini secara acak mengurutkan instance dan menetapkan nilai untuk setiap fitur kategorikal. Untuk mengurangi dampak kategori frekuensi rendah dan noise, koefisien bobot prioritas dan faktor prioritas diterapkan pada distribusi data. Hal ini dapat diwakili oleh ekspresi berikut:

$$\widehat{x}_k^i = \frac{\sum_{j=1}^n I_{\{x_j^i = x_k^i\}} \cdot y_i + \beta p}{\sum_{j=1}^n I_{\{x_j^i = x_k^i\}} + \beta} \quad (2.9)$$

di mana  $p$  dan  $\beta$  masing-masing menunjukkan nilai prior dan bobot yang sesuai.

### LightGBM

*Light Gradient-Boosting Machine* (GBM) adalah algoritma berbasis DT yang membangun pohon secara leaf-wise, berbeda dengan pendekatan depth-wise tradisional, yang menghasilkan akurasi lebih tinggi pada pohon yang lebih kompleks. Algoritma ini menonjol dengan menggabungkan dua inovasi utama: Exclusive Feature Bundling dan Gradient-based One-Side Sampling. Metodologi ini meningkatkan kinerjanya dan membedakannya dari DT gradient-boosted lainnya. Ide inti LightGBM adalah menggabungkan  $M$  pohon regresi lemah secara linier menjadi satu pohon yang kuat, yang secara matematis direpresentasikan sebagai:

$$F(x) = \sum_{m=1}^M f_m(x) \quad (2.10)$$

di mana  $f_m(x)$  dan  $F(x)$  masing-masing mewakili output dari pohon regresi lemah ke- $m$  dan output akhir. Peningkatan utama dalam LightGBM meliputi strategi leaf-wise-nya, yang ditingkatkan dengan pembatasan kedalaman, dan teknik berbasis histogram, yang keduanya berkontribusi pada efisiensi dan akurasi.

### Jaringan Neural Buatan

Para ahli neurologi dan ilmuwan mengembangkan dasar-dasar ANN untuk mensimulasikan otak manusia. Arsitektur otak manusia rumit, nonlinier, dan mengandung sistem pemrosesan paralel. Back-propagation (BP) adalah algoritma populer yang digunakan untuk perhitungan dalam persamaan ANN sebagai berikut:

$$net_m = \sum_m^N X_m W_m \quad (2.11)$$

di mana  $X_m$  adalah nilai input, dan  $W_m$  adalah bobot ANN. Setelah itu, fungsi sigmoid dengan output antara 0 dan 1, yang merupakan fungsi turunan, dihitung dengan:

$$f(net_m) = \frac{1}{1 + \exp(-net_m)} \quad (2.12)$$

di mana  $net_m$  adalah hasil dari neuron ke- $m$ . Perbedaan antara hasil algoritma,  $d_m$ , dan data yang diamati  $O_m$  dihitung sebagai:

$$E_m = d_m - O_m \quad (2.13)$$

Persamaan (2.14) digunakan untuk menghitung kesalahan. Perubahan bobot dan bobot baru dihitung dengan Persamaan (2.15) dan Persamaan (2.16), masing-masing.

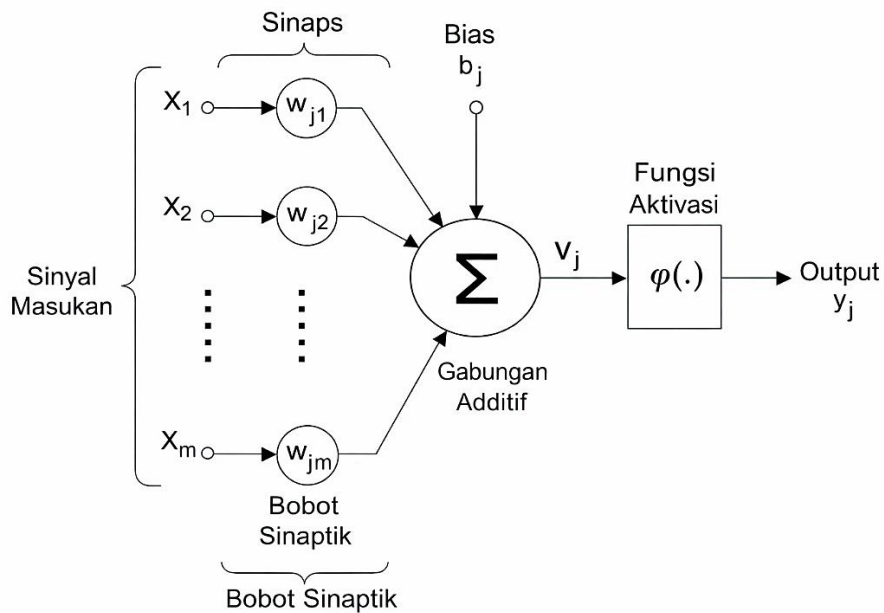


$$\delta_m = f'(net_m) \times E_m \quad (2.14)$$

$$\Delta W_{n,m}(t) = \lambda * \delta_m * O_m + \alpha * \Delta W_{n,m}(t - 1) \quad (2.15)$$

$$W_{n,m}(t) = W_{n,m}(t - 1) + \Delta W_{n,m}(t) \quad (2.16)$$

Gambar 2.4 menunjukkan struktur model ANN.



**Gambar 2.4** Struktur algoritma ANN.

### Mesin Vektor Pendukung

Boser dkk. memperkenalkan dan merumuskan mesin vektor pendukung (SVM) untuk pertama kalinya pada tahun 1992. Elemen fundamental dari pendekatan ML ini sudah dikenal dalam literatur dan telah digunakan di bidang-bidang seperti bidang hiper-margin lebar. SVM mendapatkan perhatian dalam banyak observasi, menghasilkan alat pemodelan yang unik dan efektif dengan menggabungkan dan memanfaatkan berbagai bidang seperti statika, optimasi, dan analisis fungsional. Algoritma SVM dimodifikasi menjadi serangkaian contoh yang memproyeksikan parameter input ke parameter objektif sebagai pembelajaran terawasi. Kerapatan solusi, kurangnya minimum lokal, penggunaan kernel, dan menawarkan kemampuan kontrol dengan beroperasi pada margin adalah semua aspek unik dari SVM. Model regresi SVM ditentukan oleh:

$$y = f(x) + e \quad (2.17)$$

di mana  $y$  dan  $x$  adalah sampel keluaran dan masukan yang ditentukan dalam ruang karakteristik berdimensi tinggi, masing-masing, dan  $e$  adalah kesalahan acak bebas.

### **Mesin Vektor Pendukung Kuadrat Terkecil**

LSSVM adalah versi lanjutan dari SVM. Pendekatan ini memanfaatkan lebih sedikit sampel dan memastikan akurasi yang lebih besar daripada teknik SVM. Rumusan fungsi biaya adalah sebagai berikut:

$$f(x) = w^T \varphi(x^T) + b \quad (2.18)$$

di mana  $w^T$  mengacu pada vektor keluaran yang ditransfer dan  $\varphi(x^T)$  menunjukkan algoritma kernel;  $b$  menunjukkan suku bias  $\alpha$ ;  $x^T$  mewakili masukan fungsi ini. Fungsi biaya untuk menghitung  $w$  dan  $b$  diminimalkan dalam model ini:

$$CF = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{m=1}^N e_m^2 \quad (2.19)$$

Persamaan fungsi biaya adalah sebagai berikut:

$$y_m = w^T \varphi(x^T) + b + e_m \quad (2.20)$$

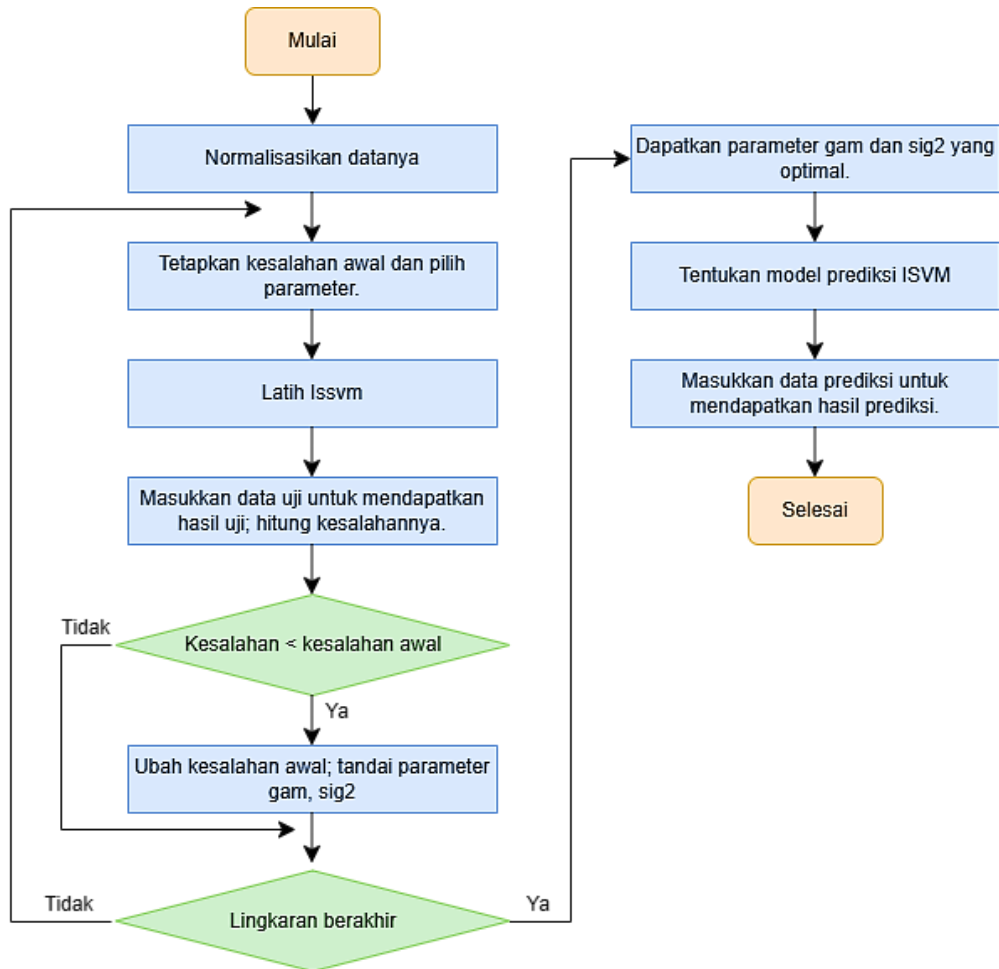
di mana  $b$  menunjukkan faktor yang dapat disesuaikan dan  $e_m$  menunjukkan kesalahan. Bentuk Lagrangiannya adalah sebagai berikut:

$$L(w, e, a, b) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{m=1}^N e_m^2 - \sum_{m=1}^N a_m (w^T \varphi(x^T) + b + e_m - y_m) \quad (2.21)$$

di mana  $a_m$  mengacu pada koefisien Lagrange. Masalah ini harus dipecahkan untuk menentukan variabel LSSVM. Kernel linear, polinomial, dan fungsi basis radial (RBF) dapat diidentifikasi seperti di bawah ini:

$$L(x, x^T) = xx^T \quad (2.22)$$





**Gambar 2.5** Diagram alur algoritma LSSVM.

$$L(x, x^T) = (\tau + xx^T)^n \quad (2.23)$$

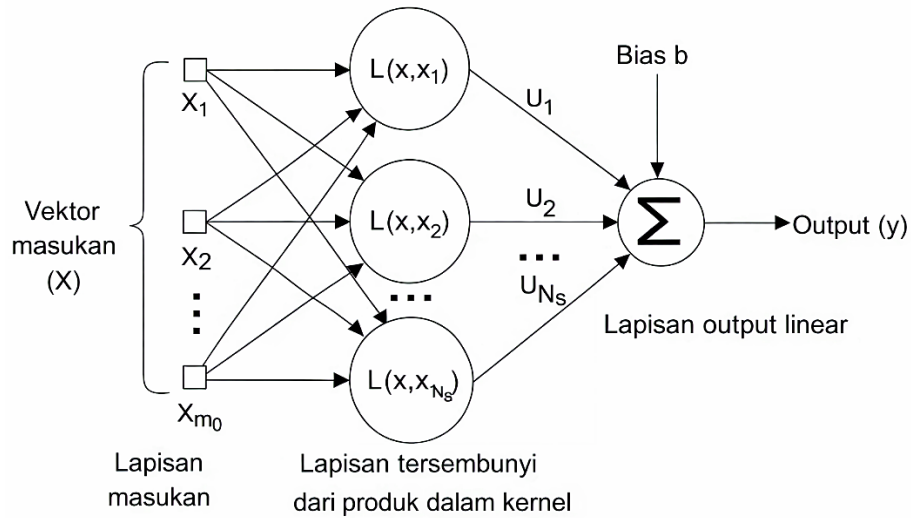
$$L(x, x^T) = \exp\left(\frac{-|x^T - x|^2}{\sigma^2}\right) \quad (2.24)$$

Diagram alir model LSSVM ditunjukkan pada Gambar 2.5. Dalam observasi ini, RBF diimplementasikan untuk prediksi karena akurasinya dalam sistem non-linier.

### Mesin Vektor Pendukung Kuadrat Terkecil Berbobot

Suykens dkk. memperkenalkan model LSSVM berbobot (WLSSVM) yang menggunakan bobot untuk memodifikasi variabel kesalahan. Algoritma WLSSVM telah menunjukkan kinerja yang sangat baik dalam masalah rekayasa struktur. WLSSVM telah diidentifikasi sebagai:

$$\text{Minimize } J(\omega, \xi) = \frac{1}{2} \omega^T \omega + \frac{1}{2} \gamma \sum_{m=1}^N W_m \xi_m^2 \quad (2.25)$$



**Gambar 2.6** Struktur model WLSSVM.

Dengan syarat  $y_m = \omega^T \phi(x) + b + \xi_m, m = 1, 2, \dots, N$  di mana  $x$  menunjukkan instance input, dan  $y_m$  adalah data output. Data input dikonversi ke ruang berdimensi lebih tinggi oleh  $\phi(x)$ .  $\omega$  menunjukkan vektor bobot.  $\xi_m$  menunjukkan variabel kesalahan, dan  $b$  mengacu pada suku bias. Pendekatan pengali Lagrange diterapkan untuk menyelesaikan masalah dual sebagai berikut:

$$L(\omega, b, \xi, a) = J(\omega, \xi) - \sum_{m=1}^N a_m (\omega^T \phi(x) + b + \xi_m - y_m) \quad (2.26)$$

Fungsi kernel RBF diidentifikasi sebagai berikut:

$$L(x, x^T) = \exp\left(-\frac{|x - x^T|^2}{2\sigma^2}\right) \quad (2.27)$$

Dengan demikian, model prediksi WLSSVM untuk prediksi diperoleh sebagai berikut:

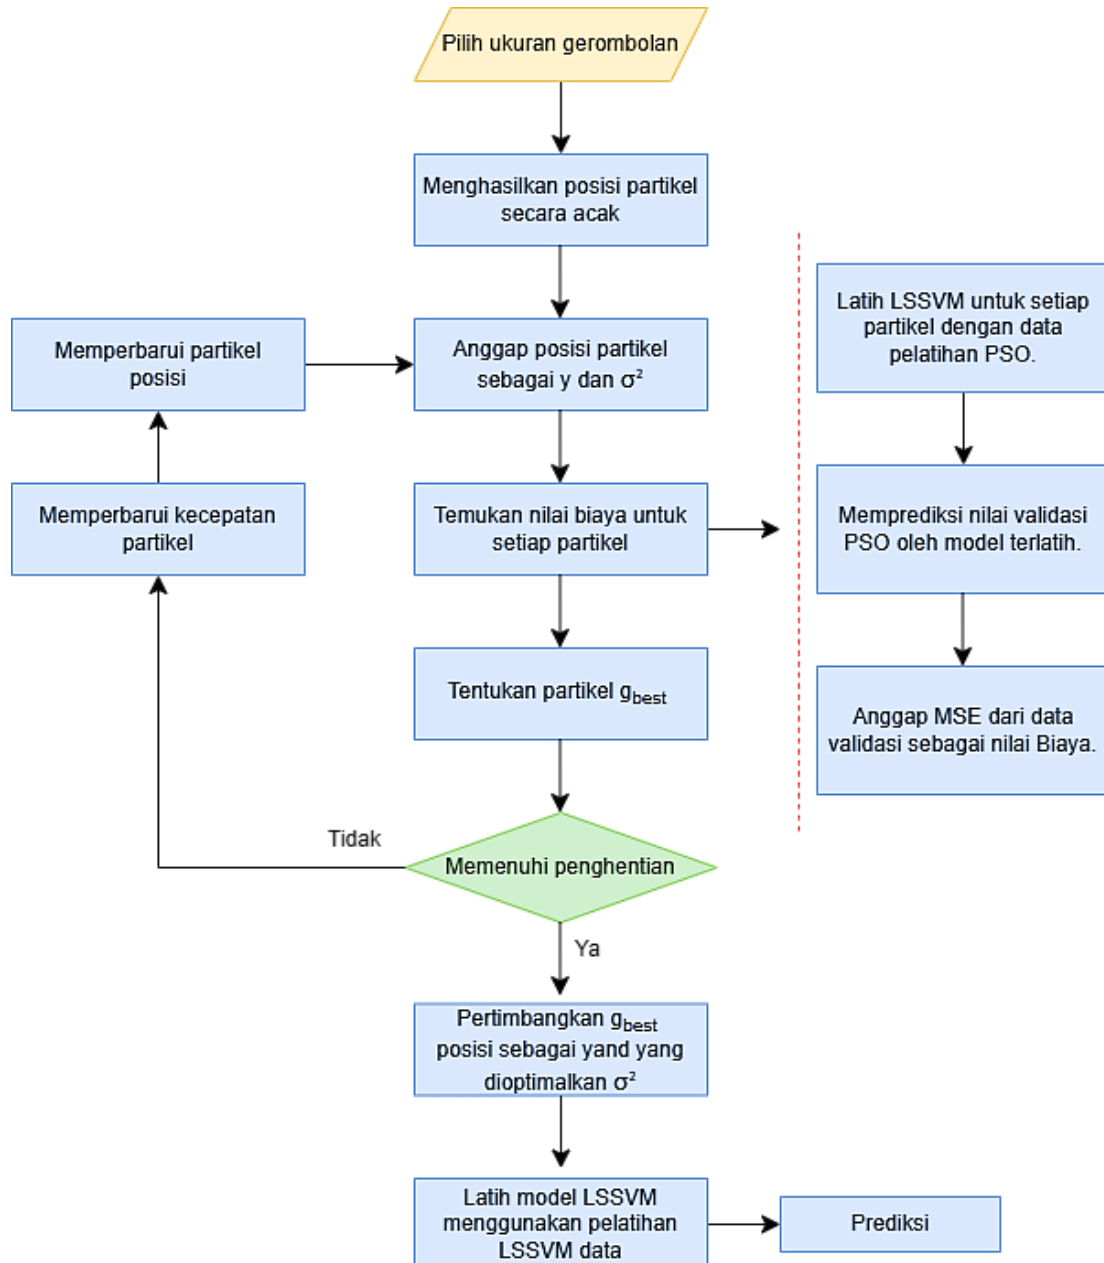
$$y(x) = \sum_{m=1}^N \alpha_m L(x, x^T) + b \quad (2.28)$$

Gambar 2.6 menggambarkan struktur algoritma WLSSVM.

### Optimasi Swarm Partikel - Mesin Vektor Pendukung Kuadrat Terkecil

Efisiensi pembelajaran dan generalisasi LSSVM harus diidentifikasi dengan menentukan parameter regularisasi ( $\gamma$ ) dan lebar fungsi kernel ( $\sigma^2$ ). Pendekatan pencarian grid sering digunakan untuk menemukan kedua parameter ini. Output komputasi yang buruk, efisiensi

terbatas, dan jangkauan pencarian yang tidak global merupakan keterbatasan prosedur ini. Metode PSO dapat digunakan untuk mengoptimalkan dan memodifikasi parameter LSSVM untuk mengatasi kekurangan ini. Gambar 2.7



**Gambar 2.7** Diagram alur algoritma PSO-LSSVM.


menunjukkan diagram alir algoritma PSO-LSSVM. Model PSO-LSSVM terdiri dari langkah-langkah berikut:


1. Nilai yang tepat untuk parameter PSO ditentukan;
2. Proses pelatihan model LSSVM diselesaikan, dan  $\gamma$  dan  $\sigma^2$  dihitung;
3. Swarm partikel dihitung dengan fungsi keputusan adaptif, seperti di bawah ini:

$$F = - \frac{\sum_{m=1}^N (|y_m - \hat{y}_m|)}{y_m} \quad (2.29)$$

4. Kesalahan kuadrat rata-rata (MSE) digunakan sebagai nilai biaya, dan parameter swarm partikel dihitung ulang menggunakan bobot yang diperbarui;
5. Jika kriteria terpenuhi, parameter optimal dihitung; jika tidak, langkah diulangi.
6. Parameter optimal yang diperoleh digunakan untuk melatih model LSSVM, dan model PSO-LSSVM dibentuk;
7. Sampel uji diprediksi.

Pengaruh nilai  $\gamma$  dan  $\sigma^2$  yang berbeda terhadap indeks kinerja pada model LSSVM diilustrasikan pada Gambar 2.8. Dapat dilihat bahwa ketika nilai  $\gamma$  berada dalam rentang 0 hingga 100, dan nilai  $\sigma^2$  mendekati 0, nilai kesalahan kuadrat rata-rata ternormalisasi (NMSE) dan kesalahan kuadrat rata-rata akar (RMSE) terkecil diperoleh.





**Gambar 2.8** Hubungan antara  $\sigma^2$ ,  $\gamma$ , dan indeks kinerja LSSVM pada: (a) NMSE fungsi tujuan 1; (b) RMSE fungsi tujuan 1; (c) NMSE fungsi tujuan 2; (d) RMSE fungsi tujuan 2.

### Mesin Vektor Pendukung Nonparalel yang tidak Sensitif terhadap Parametrik

Versi yang lebih baik dari SVM disebut PIN-SVM, yang cocok untuk regresi. PIN-SVM bertujuan untuk menghitung  $f_1(x)$  dan  $f_2(x)$  secara simultan, yang merupakan fungsi proksimal nonparalel. Selain itu, dua fungsi proksimal nonparalel yang tidak sensitif terhadap parametrik,  $g_1(x)$  dan  $g_2(x)$ , juga diestimasi.

$$f_1(x) = L(H^T, x^T)\omega_1 + b_1, f_2(x) = L(H^T, x^T)\omega_2 + b_2 \quad (2.30)$$

$$g_1(x) = L(H^T, x^T)\omega_3 + b_3, g_2(x) = L(H^T, x^T)\omega_4 + b_4 \quad (2.31)$$

di mana  $g_1(x), g_2(x) \geq 0$ , dan L adalah kernel yang sesuai. Kemudian, sepasang masalah optimasi awal dibangun sebagai berikut:

$$\min_{\omega_1, \omega_3, b_1, b_3, \xi} \frac{1}{2} c_3 (\omega_1^T \omega_1 + b_1^2 + \omega_3^T \omega_3 + b_3^2) + \frac{1}{2} \xi^{*T} \xi^* + c_1 e^T \xi$$

$$\text{s.t. } Y - (L(x, x^T)\omega_1 + eb_1) = \xi^*$$

$$\begin{aligned}
 &L(x, x^T)\omega_3 + eb_3 \geq 0 \\
 Y - (L(x, x^T)\omega_1 + eb_1) &\geq -(L(x, x^T)\omega_3 + eb_3) - \xi, \xi \geq 0
 \end{aligned} \tag{2.32}$$

Dan

$$\min_{\omega_2, \omega_4, b_2, b_4, \eta} \frac{1}{2} c_4 (\omega_2^T \omega_2 + b_2^2 + \omega_4^T \omega_4 + b_4^2) + \frac{1}{2} \eta^{*T} + c_2 e^T$$

$$\text{s.t. } (L(x, x^T)\omega_2 + eb_2) - Y = \eta^*$$

$$L(x, x^T)\omega_4 + eb_4 \geq 0$$

$$(L(x, x^T)\omega_2 + eb_2) - Y \geq -(L(x, x^T)\omega_4 + eb_4) - \eta, \eta \geq 0 \tag{2.33}$$

di mana  $\xi$  dan  $\eta$  adalah vektor kendur dan  $c_1, \dots, c_4$  adalah parameter positif. Kemudian,  $f_1(x)$ ,  $g_1(x)$  dan  $f_2(x)$ ,  $g_2(x)$  dihitung dengan menggunakan  $(\omega_1 + b_1)$ ,  $(\omega_3 + b_3)$  dan  $(\omega_2 + b_2)$ ,  $(\omega_4 + b_4)$  yang diperoleh. Model regresi kemudian dibangun dengan:

$$f(x) = \frac{1}{2} (f_1(x) + f_2(x)) = \frac{1}{2} (\omega_1 + \omega_2)^T L(x, H) + \frac{1}{2} (b_1 + b_2) \tag{2.34}$$

Batas atas dan bawah dikembangkan sebagai berikut:

$$f_1(x) - g_1(x) = (\omega_1 - \omega_3)^T L(x, H) + b_1 - b_3$$

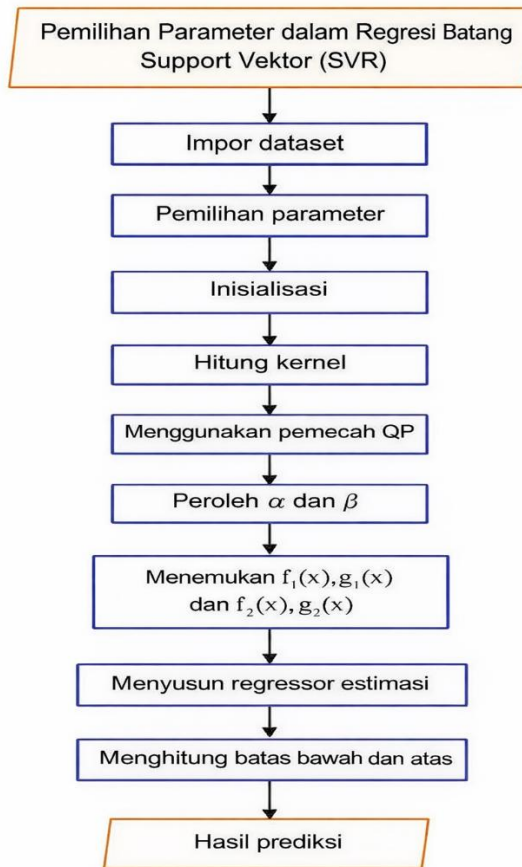
$$f_2(x) - g_2(x) = (\omega_2 - \omega_4)^T L(x, H) + b_2 - b_4 \tag{2.35}$$

Parameter untuk menyetel bobot  $c_1, \dots, c_4$ , dan parameter kernel  $P$  dipertimbangkan dalam observasi ini untuk algoritma PIN-SVM. Gambar 2.9 menggambarkan diagram alir algoritma PIN-SVM.

### **$\epsilon$ -Twin Support Vector Machine**

$\epsilon$ -TSVM diperkenalkan sebagai pendekatan yang mempertimbangkan ide TWSVM dan TSVM.  $\epsilon$ -TSVM menemukan dua fungsi linier  $\epsilon$ -insensitive sebagai:

$$g_1(x) = w_1^T x + b_1 \text{ and } g_2(x) = w_2^T x + b_2 \tag{2.36}$$



**Gambar 2.9** Diagram alur algoritma PIN-SVM.

Masalah awal dapat direpresentasikan dengan mendefinisikan istilah regularisasi  $\frac{1}{2}(w_1^T w_1 + b_1^2)$  dan  $\frac{1}{2}(w_2^T w_2 + b_2^2)$ , variabel slack  $\xi, \xi^*, \eta$ , dan  $\eta^*$ , sebagai berikut:

$$\min_{w_1, b_1, \xi, \xi^*} \frac{1}{2} c_3 (w_1^T w_1 + b_1^2) + \frac{1}{2} \xi^{*T} \xi^* + c_1 e^T \xi,$$

$$s.t. Y - (Dw_1 + eb_1) = \xi^*,$$

$$Y - (Dw_1 + eb_1) \geq -\epsilon_1 e - \xi, \xi \geq 0, \quad (2.37)$$

Dan

$$\min_{w_2, b_2, \eta, \eta^*} \frac{1}{2} c_4 (w_2^T w_2 + b_2^2) + \frac{1}{2} \eta^{*T} \eta^* + c_2 e^T \eta,$$

$$s.t. (Dw_2 + eb_2) - Y = \eta^*,$$

$$(Dw_2 + eb_2) - Y \geq -\epsilon_2 e - \eta, \eta \geq 0, \quad (2.38)$$

di mana  $c_1, c_2, \varepsilon_1$ , dan  $\varepsilon_2$  adalah parameter positif. Parameter untuk menyetel bobot  $c_1, \dots, c_6$ , dan parameter kernel  $P$  didefinisikan dalam observasi ini untuk algoritma ini. Diagram alir metode ini ditunjukkan pada Gambar 2.10.

### Mesin Vektor Pendukung Lagrange Berbobot $\varepsilon$ -Twin

WL- $\varepsilon$ -TSVM dikembangkan menggunakan ide SVM, di mana contoh-contoh diberi penalti berdasarkan pengaruhnya terhadap akurasi regresi. Masalah pemrograman kuadratik (QPP) untuk WL- $\varepsilon$ -TSVM nonlinier dapat diselesaikan dengan menerapkan kernel  $L(x, x^T)$  yang sesuai seperti di bawah ini:

$$\begin{aligned} \min_{w_1, b_1, \xi} \frac{1}{2} |G - (L(x, x^T)w_1 + eb_1)|^2 + \frac{v_1}{2} (|w_1|^2 + b_1^2) + \frac{c_1}{2} \xi^T D \\ \text{s.t. } G - (L(x, x^T)w_1 + eb_1) \geq -\varepsilon_1 e - \xi, \xi \geq 0 \end{aligned} \quad (2.39)$$

Dan

$$\begin{aligned} \min_{w_2, b_2, \eta} \frac{1}{2} |(L(x, x^T)w_2 + eb_2) - G|^2 + \frac{v_2}{2} (|w_2|^2 + b_2^2) + \frac{c_2}{2} \eta^T D \\ \text{s.t. } (L(x, x^T)w_2 + eb_2) - G \geq -\varepsilon_2 e - \eta, \eta \geq 0, \end{aligned} \quad (2.40)$$

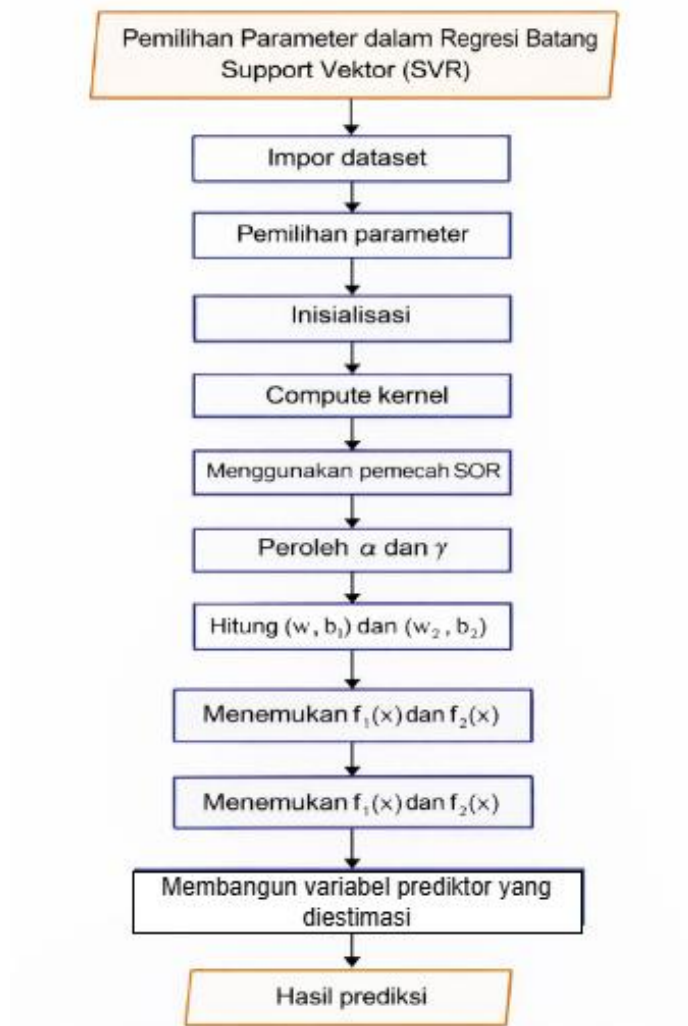
di mana  $e$  mewakili vektor satuan;  $c_1, c_2, v_1, v_2, \varepsilon_1$ , dan  $\varepsilon_2$  adalah variabel positif;  $D$  menunjukkan matriks berbobot; mengacu pada norma-2. Kriteria KKT untuk Persamaan (2.39) dapat didefinisikan sebagai:

$$-L(x, x^T)^T (G - L(x, x^T)w_1 - eb_1) + v_1 w_1 + L(x, x^T)^T \alpha = 0 \quad (2.41)$$

$$-e^T (G - L(x, x^T)w_1 - eb_1) + v_1 b_1 + e^T \alpha = 0 \quad (2.42)$$

$$c_1 D \xi - \alpha = 0 \quad (2.43)$$

$$G - (L(x, x^T)w_1 + eb_1) \geq -\varepsilon_1 e - \xi, \xi \geq 0 \quad (2.44)$$



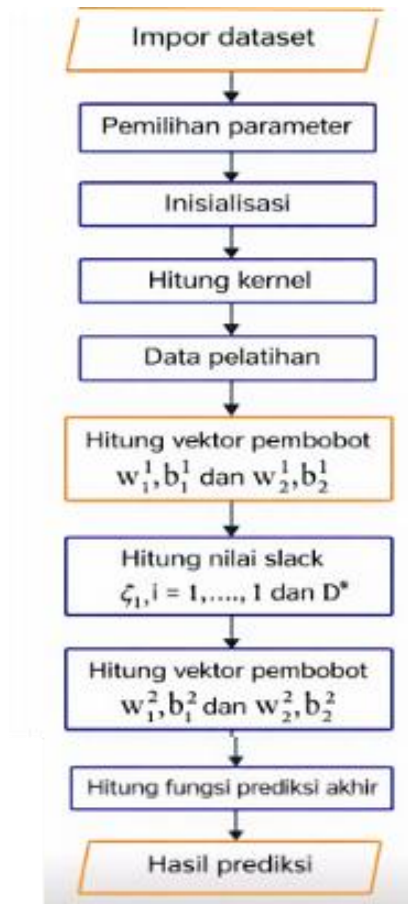
**Gambar 2.10** Diagram alir model  $\epsilon$ -TSVM.

$$\alpha^T (G - (L(x, x^T)w_1 + eb_1) + \epsilon_1 e + \xi) = 0, \alpha \geq 0 \quad (2.45)$$

Selanjutnya,  $u_2$  dicapai dengan:

$$u_2 = [w_2^T b^2]^T = (K^T K + v_2 I)^{-1} K^T (G + \gamma) \quad (2.46)$$

Parameter algoritma ini, yang dipertimbangkan dalam observasi ini, adalah parameter untuk menyesuaikan bobot  $c_1, \dots, c_{10}$ , dan parameter kernel  $P$ . Diagram alir metode ini ditampilkan pada Gambar 2.11.



Gambar 2.11 Diagram alur algoritma WL-ε-TSVM.

## 2.10 PENDEKATAN PEMBELAJARAN MESIN YANG DAPAT DIINTERPRETASIKAN

Model ML yang dikembangkan mungkin mampu membuat prediksi yang akurat; namun, model tersebut masih merupakan model kotak hitam yang tidak dapat secara eksplisit menjelaskan latar belakang mekanis atau fisik dari masalah tersebut, sehingga model ML kehilangan kredibilitas. Bab ini menginterpretasikan model menggunakan tiga pendekatan, termasuk plot ketergantungan parsial (PDP), efek lokal terakumulasi (ALE), dan SHAP, untuk mengatasi kendala ini. Signifikansi suatu faktor ditentukan dengan mengevaluasi peningkatan kesalahan estimasi setelah memodifikasi nilai faktor.

### Plot Ketergantungan Parsial

Friedman mengusulkan PDP untuk mengeksplorasi efek marginal dari variabel yang diasumsikan pada output dengan menampilkan nilai rata-rata hasil untuk berbagai parameter. PDP dapat digunakan untuk menentukan korelasi antara fitur dan tujuan. Ketergantungan parsial, yang dilambangkan dengan  $f_s$ , pada sebagian fitur  $x_s$ , dapat dinyatakan sebagai:

$$f_s(x_s) = E_{x_c}[f(x_s, x_c)] = \int f(x_s, x_c) dP(x_c) \quad (2.47)$$

di mana  $x_s$  menunjukkan faktor-faktor untuk PDP dan  $x_c$  mengacu pada faktor-faktor lainnya. PDP dapat dibuat untuk data  $\{x_i, i = 1, \dots, n\}$ , sebagai berikut:

$$\bar{f}_s(x_s) = \frac{1}{n} \sum_{i=1}^n f(x_s, x_{iC}) \quad (2.48)$$

Independensi parameter input merupakan asumsi penting dalam PDP.

### **Efek Lokal Terakumulasi**

ALE adalah varian non-bias dari PDP yang mendefinisikan efek fitur rata-rata dari algoritma ML. Jika fitur-fitur tersebut sangat terkait,  $f_s(x_s)$  dirata-ratakan di semua fitur dalam PDP, sehingga menghasilkan hasil yang bias. Masalah ini dapat diatasi dengan membatasi data ke grid tertentu. ALE merata-ratakan modifikasi dalam estimasi untuk memblokir pengaruh fitur yang berkorelasi. ALE dapat dijelaskan sebagai:

$$\begin{aligned} f_{x_s, ALE}(x_s) &= \int_{z_{0,1}}^{x_s} E_{x_c | x_s} [\widehat{f}^s(x_s, x_c) | x_s = z_s] dz_s - c \\ &= \int_{z_{0,1}}^{x_s} \int_{x_c} \widehat{f}^s(z_s, x_c) P(x_c | z_s) dx_c dz_s - c \end{aligned} \quad (2.49)$$

di mana  $c$  mewakili nilai tetap;  $\widehat{f}^s(x_s, x_c) = \frac{\delta f(x_s, x_c)}{\delta x_s}$  menunjukkan pengaruh lokal dari  $x_s$  pada  $\hat{f}(\cdot)$  pada  $(x_1, x_s)$ ;  $z_{0,1}$  mengacu pada nilai terpilih yang lebih kecil dari pengamatan terkecil;  $P(x_c | x_s)$  mengacu pada densitas.

### **Penjelasan Aditif Shapley**

Lundberg dan Lee mengusulkan teknik penjelasan aditif Shapley (SHAP) untuk mengevaluasi prediksi model berdasarkan ekspektasi bersyarat dan teori permainan. SHAP digunakan untuk menilai pengaruh faktor input yang berbeda pada setiap output. Secara umum, SHAP membantu dalam pemeringkatan fitur yang menjelaskan upaya interaksi. SHAP menyelidiki teknik atribusi fitur aditif untuk membangun model yang dapat diinterpretasikan. Kerangka kerja yang dapat diinterpretasikan dapat diungkapkan sebagai berikut:

$$f(x) = g(x') = \phi_0 + \sum_{i=1}^M \phi_i x'_i, \quad (2.50)$$

di mana  $x = (x_1, x_2, \dots, x_p)$  mewakili  $M$  variabel input;  $p$  menunjukkan jumlah instance;  $x'_i$  mengacu pada input yang disederhanakan. Dengan menggunakan fungsi proyeksi,  $x = h_x(x')$ , parameter  $x'$  ditransfer ke  $x$ . Selain itu,  $\phi_0$  dan  $\phi_i$  masing-masing menunjukkan nilai tetap dan pengaruh setiap parameter.

### 2.11 METODE PENGEMBANGAN UNTUK ALGORITMA ML

Validasi silang K-fold (CV) untuk mengurangi overfitting, pendekatan Taguchi untuk penyetelan parameter, dan teknik untuk preferensi urutan berdasarkan kesamaan dengan solusi ideal (TOPSIS) untuk perhitungan respons disajikan di bagian ini, dan deskripsi luas dapat diperoleh dari referensi yang ditawarkan.

#### Validasi Silang K-Fold

Validasi silang K-fold adalah metode validasi populer untuk proses penyetelan parameter. CV adalah pendekatan resampling untuk mengevaluasi algoritma ML. Dalam teknik ini, sampel yang diberikan dibagi menjadi beberapa subset menggunakan variabel K sebagai input. Setelah membagi dataset secara acak menjadi K subbidang berukuran sama, K-1 subsampel digunakan untuk pelatihan dan sisanya digunakan untuk verifikasi. Prosedur ini diulangi hingga semua subset telah divalidasi setidaknya sekali.

Akurasi total model pada set pelatihan dihitung dengan merata-ratakan akurasi yang diperoleh di setiap lipatan. Disarankan untuk mempertimbangkan waktu perhitungan dan bias saat menentukan nilai K. Manfaat signifikan dari pendekatan ini adalah bahwa ia menggunakan semua subsampel untuk pelatihan dan validasi. Gambar 2.12 menunjukkan model CV tiga lipatan dalam bentuk skematis. Dua belas sampel dari set pelatihan disimbolkan dan dibagi menjadi tiga kategori.



**Gambar 2.12** Skema validasi silang tiga lipatan.

#### Penyetelan Hiperparameter

Setelah dataset disiapkan dan teknik ML dipilih, langkah selanjutnya adalah menentukan hiperparameter model, yang sangat penting untuk keberhasilan model. Pendekatan Taguchi adalah metode yang efisien untuk menyetel variabel algoritma. Metode ini menerapkan serangkaian array ortogonal yang menyimpan informasi tentang faktor-faktor, termasuk faktor noise dan sinyal. Metode ini bertujuan untuk mengurangi efek noise dan menyimpulkan tingkat optimum variabel sinyal dengan prinsip kekokohan. Akibatnya, rasio sinyal terhadap noise ( $S/N$ ) diimplementasikan untuk menghitung kuantitas varians respons. Pengurangan  $S/N$  adalah tujuan observasi ini.  $S/N$  diukur sebagai:

$$\frac{S}{N} = -10 \times \log \left( \frac{S(Y^2)}{n} \right) \quad (2.51)$$

di mana  $n$  adalah jumlah array ortogonal, dan  $Y$  menunjukkan nilai respons.  $S(Y^2)$  mengacu pada penjumlahan respons  $Y^2$ .

Karena variabel metode meta-heuristik sangat sensitif, metode Taguchi juga digunakan untuk menyetel variabel algoritma optimasi swarm partikel multi-objektif (MOPSO). Keragaman dan konvergensi adalah dua tujuan utama dalam teknik evolusi multi-objektif; oleh karena itu, jarak generasi terbalik (IGD) dan hipervolume (HV) keduanya merupakan metrik yang sesuai. IGD menunjukkan konvergensi dan keragaman hasil. IGD dapat dijelaskan sebagai:

$$IDG(P, P^*) = \frac{\sum_{v \in P} d(v, P^*)}{|P^*|} \quad (2.52)$$

di mana  $P^*$  didistribusikan di atas front Pareto aktual;  $P$  mengacu pada front Pareto estimasi;  $d(v, P^*)$  menunjukkan jarak Euclidean minimum antara  $v$  dan  $P^*$ . IGD yang lebih rendah menghasilkan efikasi  $P$  yang lebih tinggi.

HV adalah salah satu metrik kinerja yang paling terkenal yang memperhitungkan konvergensi dan variasi model optimal. Nilai HV yang lebih besar lebih disukai karena menunjukkan konvergensi yang mulus dan himpunan jawaban yang terdistribusi dengan baik untuk masalah optimasi minimisasi. HV menunjukkan kedekatan dan keragaman, dan dicapai dengan menghitung HV dari front Pareto aproksimasi dengan titik referensi yang dapat dijelaskan sebagai:

$$HV(P) = \{ \cup_i a(x_i) \mid \forall x_i \in P \} \quad (2.53)$$

di mana  $x_i$  menunjukkan individu dalam front Pareto  $P$ ;  $a(x_i)$  mewakili area persegi panjang yang dibatasi oleh  $f(x_i)$  dan titik referensi sebagai  $[\max(f_1), \max(f_2)]$ . HV yang lebih tinggi menghasilkan himpunan solusi  $P$  dengan efikasi yang lebih tinggi. Dalam observasi ini, parameter respons untuk penyetelan parameter MOPSO adalah rasio kombinatorial (CR) yang diukur sebagai:

$$CR = \frac{IGD}{HV} \quad (2.54)$$

Metode efisien lainnya untuk penyetelan hyperparameter adalah dengan menggunakan kombinasi pendekatan pencarian grid dan  $K$ -fold CV untuk menghindari overfitting. Rentang potensial setiap parameter pertama-tama ditetapkan sebagai grid berdasarkan literatur. Model kemudian dilatih berulang kali menggunakan semua kemungkinan kombinasi grid parameter, dan kinerjanya dievaluasi menggunakan  $K$ -fold CV.

#### **Teknik untuk Preferensi Urutan Berdasarkan Kesamaan dengan Solusi Ideal**

Teknik ini adalah pendekatan pengambilan keputusan multi-kriteria untuk memilih jawaban terbaik dari sekelompok opsi yang tidak didominasi. Tujuan utama metode ini adalah

untuk menemukan solusi yang lebih dekat dengan jawaban optimal dan menjauh dari solusi negatif. Langkah-langkah berikut menyajikan prosedur TOPSIS:

*Langkah 1:* TOPSIS adalah pendekatan penentuan tingkat yang sederhana dan masuk akal yang mempertimbangkan nilai-nilai yang dinormalisasi sebagai berikut:

$$R_{mn} = \frac{R_{mn}}{\sqrt{\sum_m^N R_{mn}^2}} \quad (2.55)$$

di mana  $R$  mewakili semua solusi dan  $R_{mn}$  menunjukkan solusi ke- $m$  dari keluaran ke- $n$ .

*Langkah 2:* Nilai tertimbang yang dinormalisasi diperoleh dengan mengalikan peringkat yang dinormalisasi ( $R_{mn}$ ) dan bobot ( $W_n$ ):

$$\hat{R}_{mn} = R_{mn} \times W_n \quad (2.56)$$

*Langkah 3:* Nilai ideal terburuk ( $R^-$ ) dan nilai ideal terbaik ( $R^+$ ) ditentukan:

$$R^- = (\max(\hat{R}_{11}, \hat{R}_{21}, \hat{R}_{31}, \dots, \hat{R}_{m1}), \min(\hat{R}_{12}, \hat{R}_{22}, \hat{R}_{32}, \dots, \hat{R}_{m2})) \quad (2.57)$$

$$R^+ = (\min(\hat{R}_{11}, \hat{R}_{21}, \hat{R}_{31}, \dots, \hat{R}_{m1}), \max(\hat{R}_{12}, \hat{R}_{22}, \hat{R}_{32}, \dots, \hat{R}_{m2})) \quad (2.58)$$

*Langkah 4:* Ukuran jarak  $p^-$  dan  $p^+$  dievaluasi dari  $R^-$  dan  $R^+$  untuk setiap alternatif menggunakan rumus berikut:

$$p_m^- = \sqrt{\sum_{n=1}^2 (\hat{R}_{mn} - R^-)^2} \quad (2.59)$$

$$p_m^+ = \sqrt{\sum_{n=1}^2 (\hat{R}_{mn} - R^+)^2} \quad (2.60)$$

*Langkah 5:* Kedekatan relatif ( $P_m$ ) dihitung dengan:

$$P_m = \frac{p_m^-}{p_m^+ + p_m^-} \quad (2.61)$$

*Langkah 6:* Solusi yang paling diinginkan dipilih berdasarkan nilai  $P_m$  yang paling dekat dengan 1.



## 2.12 INDIKATOR KINERJA AKURASI

Pada bagian ini, beberapa indikator telah diusulkan yang sering digunakan untuk menilai akurasi algoritma ML. Indikator kinerja paling populer yang saat ini digunakan untuk mengukur akurasi adalah deviasi relatif rata-rata (ARD), NMSE, RMSE, deviasi standar (SD), dan koefisien korelasi ( $R$ ) yang dapat dihitung sebagai berikut:

$$ARD(\%) = \frac{100}{N} \sum_{m=1}^N \left( \frac{g_m - f_m}{f_m} \right) \quad (2.62)$$

$$NMSE = \frac{1}{\delta^2 N} \sum_{m=1}^N (f_m - g_m)^2, \delta^2 = \frac{1}{N-1} \sum_{m=1}^N (f_m - \bar{f})^2 \quad (2.63)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{m=1}^N (f_m - g_m)^2} \quad (2.64)$$

$$SD = \sqrt{\frac{1}{N-1} \sum_{m=1}^N (g_m - \bar{g})^2} \quad (2.65)$$

$$R = \frac{\sum_{m=1}^N (f_m - \bar{f})(g_m - \bar{g})}{\sqrt{\sum_{m=1}^N (f_m - \bar{f})^2 \sum_{m=1}^N (g_m - \bar{g})^2}} \quad (2.66)$$

di mana  $N$  adalah jumlah sampel uji;  $f_m$  menunjukkan nilai aktual,  $g_m$  menunjukkan nilai yang diantisipasi,  $\bar{f}$  mewakili rata-rata nilai sebenarnya, dan  $\bar{g}$  menunjukkan rata-rata nilai yang diestimasi. ARD mengkarakterisasi derajat penyimpangan antara nilai aktual dan nilai prediksi. NMSE dan RMSE menghitung perbedaan antara nilai prediksi dan nilai aktual. SD digunakan untuk menghitung penyimpangan nilai prediksi terhadap nilai rata-ratanya.  $R$  diterapkan untuk mengukur derajat ketergantungan linier antara nilai prediksi dan nilai sebenarnya.

## 2.13 ALGORITMA OPTIMASI SWARM PARTIKEL MULTI-OBJEKTIF

PSO adalah model heuristik berbasis populasi berdasarkan perilaku sosial hewan. PSO menggunakan swarm partikel yang ditingkatkan secara iteratif untuk menemukan solusi terbaik global.  $X_{i,N}(t)$  mewakili posisi, dan  $V_{i,N}(t)$  menunjukkan karakteristik kecepatan terkait ruang pencarian multidimensi  $N$  pada generasi ke- $t$  untuk partikel ke- $i$ . Kecepatan dan posisi partikel ke- $i$  dapat disesuaikan seperti di bawah ini:

$$V_{i,N}(t+1) = \omega(t+1)V_{i,N}(t) + c_1 r_1 (X_{pbest,N} - X_{i,d}(t))$$

$$+c_2r_2(X_{pbest,N} - X_{i,d}(t)) \quad (2.67)$$

$$X_{i,N}(t + 1) = X_{i,N}(t) + V_{i,N}(t + 1) \quad (2.68)$$

di mana  $1 \leq t \leq k$ ;  $1 \leq i \leq m$ ; dengan  $m$  adalah jumlah partikel;  $t$  dan  $k$  masing-masing menunjukkan iterasi saat ini dan maksimum;  $c_1$  dan  $c_2$  menunjukkan koefisien percepatan;  $r_1$  dan  $r_2$  menunjukkan vektor acak dengan nilai antara 0 dan 1. Pengendalian pengaruh kecepatan sebelumnya terhadap kecepatan saat ini dapat dicapai dengan  $\omega$  sebagai bobot inersia sebagai berikut:

$$\omega(t) = \omega(1) - (\omega(1) - \omega(k)) \frac{t}{k} \quad (2.69)$$

Oleh karena itu, berbagai variabel ditetapkan, yaitu koefisien percepatan ( $c_1$ ), koefisien percepatan ( $c_2$ ), bobot inersia ( $W$ ), ukuran populasi ( $PS$ ), dan jumlah iterasi ( $NOI$ ). Proses iteratif diulangi untuk memenuhi kriteria penghentian. Coello dan Lechuga menawarkan beberapa fungsi tujuan dalam MOPSO yang mempertimbangkan repositori untuk menyimpan solusi non-dominan. MOPSO memiliki tingkat kekokohan yang tinggi, kecepatan konvergensi yang tinggi, dan keandalan yang membuatnya bermanfaat dalam menentukan nilai optimal lokal. Langkah-langkah MOPSO adalah sebagai berikut:

1. Menghasilkan serangkaian permutasi acak untuk digunakan sebagai populasi utama;
2. Menghitung skor permutasi yang dihasilkan menggunakan vektor bobot;
3. Menemukan permutasi non-dominan dan menyesuaikan arsip;
4. Meningkatkan nilai terbaik lokal dan global;
5. Memilih permutasi pemimpin untuk setiap partikel;
6. Menghitung vektor kecepatan menggunakan Persamaan. (2.67);
7. Ubah lokasi partikel menggunakan Persamaan (2.68);
8. Ulangi langkah (2) hingga (7) sampai kondisi penghentian terpenuhi dan kemudian dapatkan arsip akhir sebagai front Pareto.

Hasil optimasi dari proses MOPSO adalah kumpulan solusi Pareto optimal, bukan solusi tunggal. Titik-titik Pareto optimal yang dihasilkan adalah solusi terbaik ketika kondisi antagonistik hadir. Nilai fungsi tujuan yang tidak didominasi dalam himpunan Pareto optimal ditampilkan pada front Pareto.

## 2.14 ANALISIS ELEMEN HINGGA

FEA adalah metode analisis numerik yang cocok untuk analisis struktural dan mendapatkan reaksi struktural yang dikenai gaya dunia nyata. Dalam bab ini, metode ini diimplementasikan untuk analisis struktural cangkang grid elastis GFRP untuk mempersiapkan dataset dan memverifikasi keakuratan metode yang disajikan dengan program ABAQUS.

Modul adalah unit fungsional ABAQUS. Setiap modul berisi alat-alat spesifik yang terkait dengan tugas pemodelannya.

Tugas pemodelan setiap modul adalah sebagai berikut: Modul Part untuk membuat geometri; Modul Property untuk definisi material dan pembuatan penampang; Modul Assembly untuk merakit instance; Modul Step untuk mendefinisikan langkah-langkah analisis dan output yang dibutuhkan; Modul Interaction untuk menentukan interaksi; Modul Load untuk mendefinisikan beban dan kondisi batas; Modul Mesh untuk membuat mesh elemen hingga; Modul Optimization untuk konfigurasi tugas optimasi; Modul Job untuk melakukan analisis dan mengontrol kemajuannya; Modul Visualization untuk melihat hasilnya; Modul Sketch untuk membuat sketsa 2D. Aplikasi setiap modul disajikan untuk implementasi FEA pada bab-bab berikut.

## **2.15 DESAIN GRIDSHELL ELASTIS GFRP DENGAN ML**

Struktur gridshell menawarkan pendekatan transformatif untuk konstruksi desain bentuk bebas, memberikan beberapa keuntungan seperti penggunaan material minimal, konstruksi ringan, kemampuan untuk membuat struktur bentang lebar, dan peningkatan efisiensi struktural. Keberlanjutan dan kemudahan pembongkaran serta daur ulangnya semakin menggarisbawahi daya tariknya. Dengan memanfaatkan rasionalitas geometris intrinsiknya, gridshell sangat cocok untuk pembuatan permukaan lengkung ganda. GFRP adalah material ideal untuk struktur ini karena sifat mekaniknya yang menguntungkan. Selain itu, di antara berbagai pendekatan AI, ML telah mendapatkan perhatian yang signifikan sebagai metode cerdas yang menjanjikan untuk memberikan solusi rekayasa struktural yang inovatif. Bab ini meninjau metode desain dan konstruksi untuk struktur gridshell elastis GFRP, menyoroti baik peluang yang mereka tawarkan maupun tantangan yang harus diatasi.

Bab ini menyajikan tinjauan komprehensif tentang berbagai teknik ML dan model yang paling relevan. Semua algoritma ML yang dibahas dapat diterapkan pada masalah regresi dan mencakup LR, RR, KNN, DT, RF, AdaBoost, XGBoost, CatBoost, LightGBM, ANN, SVM, LSSVM, WLSSVM, PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM. Selain itu, bab ini menyoroti pendekatan ML yang dapat diinterpretasikan seperti nilai PDP, ALE, dan SHAP. Bab ini juga menjelaskan prosedur untuk K-fold CV, metode Taguchi, pencarian grid, TOPSIS, dan berbagai indeks kinerja, termasuk ARD, NMSE, RMSE, SD, dan  $R$ . K-fold CV ditekankan sebagai metode yang efisien untuk mengurangi overfitting, sementara penyetelan parameter yang cermat dari algoritma ML sangat penting untuk mencapai akurasi yang lebih tinggi. Proses Taguchi digunakan untuk menemukan parameter optimal, dengan memanfaatkan respons yang dihitung oleh metode TOPSIS bersamaan dengan indeks kinerja.

Algoritma PSO dan MOPSO dibahas secara detail, menyoroti signifikansinya dalam teknik sipil sebagai teknik optimasi yang efektif untuk menangani variabel diskrit dan kendala serta tujuan yang sembarang. Para peneliti telah berhasil menerapkan PSO sebagai metode optimasi stokastik yang terinspirasi dari alam, yang telah populer dalam beberapa tahun terakhir karena kemampuannya untuk menemukan solusi yang mendekati optimal. Kesederhanaannya, parameter minimal yang dibutuhkan, dan mekanisme eksplorasi yang

efisien berkontribusi pada biaya komputasi yang lebih rendah dibandingkan dengan metode heuristik lainnya. Selain itu, studi ini mengklarifikasi implementasi FEA dalam konteks algoritma ini. Kesimpulannya, cangkang grid elastis GFRP menghadirkan potensi dan peluang yang signifikan untuk membangun permukaan lengkung ganda dengan memanfaatkan pendekatan ML untuk mengatasi tantangan terkait.

## **BAB 3**

### **PREDIKSI BENTUK BATANG RAMPING DISKRIT**

#### **3.1 KONSTRUKSI PENGANGKATAN & ANALISIS DISKRIT GRIDSHHELL**

Struktur gridshell, yang dikenal karena desainnya yang ringan dan efisien, bergantung pada prinsip konstruksi dan mekanik tertentu untuk memastikan stabilitas dan kinerja. Salah satu pendekatan tersebut melibatkan penyederhanaan elemen yang diangkat dari struktur gridshell sebagai balok kantilever yang dikenai berat sendiri dan beban terpusat. Penyederhanaan ini dicapai dengan menciptakan penyangga kaku pada penampang sepanjang garis simetris, seperti yang ditunjukkan dalam observasi sebelumnya. Prinsip elemen diskrit dapat digunakan untuk menganalisis model mekanik ini, di mana balok kantilever didiskretisasi menjadi segmen-segmen di antara titik-titik gaya terpusat yang berdekatan. Kurva deformasi balok dapat diperoleh dengan mendefinisikan deformasi semua elemen diskrit, memungkinkan prediksi struktural yang lebih akurat. Selain itu, kemajuan dalam kecerdasan buatan (AI), khususnya algoritma pembelajaran mesin (ML), menawarkan solusi alternatif dan inovatif untuk analisis struktural. Dengan melatih model AI dengan dataset yang sesuai, dimungkinkan untuk memprediksi bentuk dan perilaku elemen struktural di bawah berbagai kondisi pembebanan, sehingga mengurangi ketergantungan pada metode analitis tradisional. Selain itu, mengintegrasikan pemodelan informasi bangunan (BIM) ke dalam desain dan konstruksi gridshell semakin meningkatkan proses tersebut.

Tantangan signifikan dalam konstruksi gridshell adalah mengelola pembentukan bentuk grid datar selama proses pemasangan. Fernandes dkk. meninjau teknik konstruksi untuk gridshell, dengan Peloux dkk. memperkenalkan metode pengangkatan untuk gridshell polimer yang diperkuat serat kaca (GFRP), menyoroti keunggulannya dalam efisiensi tenaga kerja dan waktu. Daya tahan dan kekuatan profil GFRP juga meminimalkan risiko kerusakan elemen di dekat simpul pengangkatan, masalah umum saat menggunakan gridshell kayu. Vault mengeksplorasi pembentukan gridshell melalui proses konstruksi peregangan, menggunakan teknik batang elastis diskrit untuk menganalisis bentuk akhir. Xiang dkk. mengusulkan metode pemasangan pengangkatan yang menunjukkan keamanan dan efisiensinya dalam konstruksi gridshell. Selain itu, optimasi prosedur pemasangan gridshell merupakan aspek penting lainnya dari proses tersebut. Proses konstruksi dapat disesuaikan secara dinamis untuk mencapai jalur paling efisien menuju struktur akhir dengan menggabungkan teknik optimasi.

#### **3.2 PROSES KONSTRUKSI PENGANGKATAN**


Memilih metode konstruksi yang tepat untuk struktur cangkang kisi elastis merupakan masalah krusial. Teknik konstruksi pengangkatan, yang umumnya dilakukan dengan derek, merupakan pendekatan yang praktis dan mudah. Kabel awalnya dihubungkan ke kait derek, dan kisi datar dibangun, setelah itu kisi diangkat dan dideformasi secara elastis. Gambar 3.1 mengilustrasikan model dua dimensi (2D) yang disederhanakan dari elemen ramping yang

dikenai beban ke atas yang diterapkan pada simpul pengangkatan. Selain berat sendiri elemen, titik persimpangan elemen longitudinal dan transversal dikenai beban terpusat ekuivalen ke bawah. Pada sambungan, besarnya setiap beban terpusat ke bawah sama dengan jumlah gravitasi segmen elemen longitudinal dan konektor.

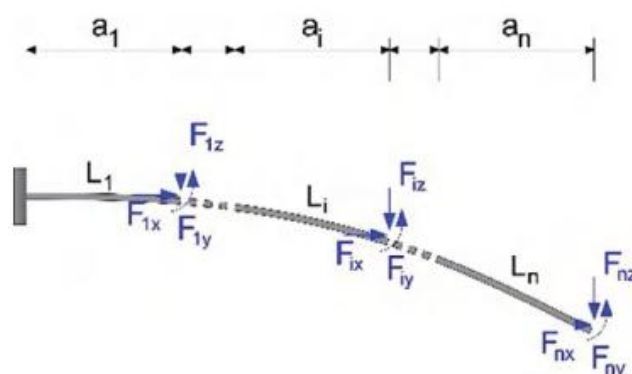
### 3.3 METODOLOGI

#### Penurunan Persamaan Dasar

Gambar 3.2 menunjukkan elemen yang diangkat yang disederhanakan dengan memberikan dukungan kaku sebagai balok kantilever. Beban terpusat, termasuk  $f_{ix}$ ,  $f_{iy}$  dan  $f_{iz}$ , diterapkan pada balok. Pada bab ini, elemen diskrit disajikan untuk analisis model mekanik tersebut. Balok kantilever dapat didiskretisasi menjadi segmen-segmen dengan mempertimbangkan titik aplikasi gaya terpusat. Elemen diskrit didefinisikan sebagai segmen-segmen anggota ini. Suatu elemen diskrit  $i$  dianggap sebagai balok kantilever dengan beban terpusat  $f_{ix}$ ,  $f_{iy}$ , dan  $f_{iz}$  pada ujung bebas dan rotasi  $\theta_{li}$  pada tumpuan, seperti yang diilustrasikan pada Gambar 3.3.



Gambar 3.1 Sebuah elemen dari struktur cangkang kisi.



Gambar 3.2 Model analisis untuk satu elemen.

Selanjutnya,  $\theta_{2i}$  menunjukkan sudut kemiringan pada ujung bebas dalam keadaan keseimbangan. Berat sendiri segmen balok diperhitungkan dalam model elemen diskrit. Kurva

deformasi anggota struktural pada grid dua lapis dan balok kantilever dapat diperoleh dengan mendefinisikan deformasi semua elemen diskrit.

Nilai  $f_{ix}$ ,  $f_{iy}$ , dan  $f_{iz}$  untuk elemen diskrit  $i$  berkaitan dengan deformasi elemen diskrit lainnya dalam keadaan kesetimbangan. Rumusan dasar untuk respons elemen diskrit perlu diklarifikasi. Dengan mempertimbangkan  $f_{ix}$ ,  $f_{iy}$ , dan  $f_{iz}$  sebagai variabel yang diketahui, penurunan persamaan dasar diusulkan. Panjang elemen diskrit  $i$  dapat direpresentasikan dalam bentuk integral, berdasarkan sistem koordinat yang digambarkan pada Gambar 3.3, sebagai berikut:

$$L_i = \int_0^{a_i} \sqrt{1 + z_i'(x_i)^2} dx_i \quad (3.1)$$


di mana  $L_i$  dan  $a_i$  masing-masing menunjukkan panjang elemen diskrit  $i$  dan panjang pemetaan pada sumbu  $x$  dalam keadaan setimbang. Tabung GFRP pultruded melingkar digunakan sebagai objek studi dalam bab ini karena umumnya digunakan dalam struktur gridshell.  $I$  menunjukkan momen inersia penampang, dan  $q$  mewakili berat sendiri tabung GFRP per satuan panjang, yang dapat diukur dengan:

$$I = \frac{\pi[D^4 - (D - 2t)^4]}{64} \quad (3.2)$$

$$q = \frac{\pi[D^2 - (D - 2t)^2]}{4} dg \quad (3.3)$$

di mana  $D$  menunjukkan diameter luar;  $t$  mewakili ketebalan dinding bagian tabung;  $d$  adalah densitas material GFRP; dan  $g$  menunjukkan percepatan gravitasi. Untuk benda bebas yang digambarkan pada Gambar 3.3, kondisi kesetimbangan dapat diperoleh menggunakan persamaan berikut:

$$M_i(x_i) = \int_{x_i}^{a_i} q \sqrt{1 + z_i'(x')^2} (x' - x_i) dx' - F_{iy} + F_{iz}(a_i - x_i) - F_{ix}(b_i - z_i(x_i)) \quad (3.4)$$



**Gambar 3.3** Analisis keseimbangan: (a) elemen diskrit  $i$ ; (b) keseimbangan benda bebas.

Asumsi prinsip balok Euler–Bernoulli yang mengabaikan deformasi geser cocok untuk elemen struktur yang ramping. Oleh karena itu, momen lentur penampang elemen dapat dihitung sebagai:

$$M_i(x_i) = \frac{EI}{\rho(x_i)} \tag{3.5}$$

di mana  $E$  mewakili modulus Young. Modulus lentur efektif dapat digunakan untuk tabung GFRP pultruded yang terutama mengalami pembengkokan. Jari-jari kelengkungan elemen GFRP yang dipelajari diwakili oleh  $\rho(x_i)$ . Hubungan antara kurva deformasi  $z(x_i)$  dan jari-jari kelengkungan  $\rho(x_i)$  dapat dinyatakan dengan mempertimbangkan efek deformasi geometris yang besar, sebagai berikut:

$$\frac{1}{\rho(x_i)} = \frac{z_i''(x_i)}{(1 + z_i'(x_i)^2)^{3/2}} \tag{3.6}$$

Persamaan berikut dapat diturunkan menggunakan Persamaan (3.4), (3.5), dan (3.6) sebagai berikut:

$$\begin{aligned} \frac{EI z_i''(x_i)}{(1 + z_i'(x_i)^2)^{3/2}} &= \int_{x_i}^{a_i} q \sqrt{1 + z_i'(x')^2} (x' - x_i) dx' - F_{iy} \\ &+ F_{iz}(a_i - x_i) - F_{ix}(b_i - z_i(x_i)) \end{aligned} \tag{3.7}$$

Ini adalah persamaan pengatur kurva deformasi elemen diskrit  $i$ . Meskipun demikian, ini adalah masalah yang menantang untuk dipecahkan karena kerumitannya. Hipotesis yang valid ditetapkan untuk melengkapi solusi dan menyederhanakan rumus pengatur (yaitu, Persamaan (3.7)).  $q \cdot \sqrt{1 + z_i'(x')^2}$  mengacu pada kepadatan beban gravitasi anggota dalam arah  $x_i$ . Ini dapat dianggap sebagai gaya yang terdistribusi tidak seragam yang diterapkan pada elemen diskrit sepanjang sumbu horizontal  $x_i$ . Distribusi beban terkait erat dengan kurva deformasi elemen. Meskipun demikian, beban yang terdistribusi tidak seragam dianggap terdistribusi linier dalam rentang  $a_i$  untuk penyederhanaan. Beban terdistribusi dasar ini dapat ditulis sebagai  $q \cdot \left(\frac{\mu_{2i} - \mu_{1i}}{a_i} x' + \mu_{1i}\right)$ , di mana pengali beban terdistribusi ekuivalen di kedua sisi elemen diskrit  $i$  dilambangkan dengan  $\mu_{1i}$  dan  $\mu_{2i}$  dan dapat direpresentasikan sebagai:

$$\mu_{1i} = \sqrt{1 + z_i'(0)^2} \tag{3.8}$$

$$\mu_{2i} = \sqrt{1 + z_i'(a_i)^2} \tag{3.9}$$

Selain itu,  $\mu_{1i}$  dan  $\mu_{2i}$  harus selalu memenuhi kriteria berikut terkait kompatibilitas deformasi antara elemen diskrit yang berdekatan:

$$\mu_{1i} = \begin{cases} 1 & \text{untuk } i = 1 \\ \mu_{2(i-1)} & \text{untuk } i \geq 2 \end{cases} \quad (3.10)$$

$\mu_{1i}$  dan  $\mu_{2i}$  diasumsikan sebagai konstanta yang diketahui dalam penurunan selanjutnya di bagian ini. Oleh karena itu, Persamaan (3.7) disesuaikan menjadi sebagai berikut:

$$\frac{EI z_i''(x_i)}{(1 + z_i'(x_i)^2)^{\frac{3}{2}}} = \int_{x_i}^{a_j} q \left( \frac{\mu_{2i} - \mu_{1i}}{a_i} x' + \mu_{1i} \right) (x' - x_i) dx' - F_{iy} + F_{iz}(a_i - x_i) - F_{ix}(b_i - z_i(x_i)) \quad (3.11)$$

Persamaan (3.11) dapat dinyatakan lebih lanjut dengan memasukkan suku pertama di sisi kanan sebagai berikut:

$$\frac{EI z_i''(x_i)}{(1 + z_i'(x_i)^2)^{\frac{3}{2}}} = q(a_i - x_i)^2 \cdot \frac{a_i(\mu_{1i} + 2\mu_{2i}) + x_i(\mu_{2i} - \mu_{1i})}{6a_i} - F_{iy} + F_{iz}(a_i - x_i) - F_{ix}(b_i - z_i(x_i)) \quad (3.12)$$

Nilai utama  $z_i(x)$  dapat diperoleh dengan mempertimbangkan kondisi batas elemen diskrit:

$$\begin{cases} z_i(0) = 0 \\ z_i'(0) = \sqrt{\mu_{1i}^2 - 1} \end{cases} \quad (3.13)$$

Dalam hal kondisi batas dan persamaan pengatur, analisis kurva deformasi elemen diskrit i merupakan masalah nilai utama persamaan diferensial orde kedua Persamaan (3.12), (3.13) yang dapat ditulis sebagai:

$$\begin{cases} z_i''(x_i) = \frac{(1 + z_i'(x_i)^2)^{\frac{3}{2}}}{EI} \left[ q(a_i - x_i)^2 \cdot \frac{a_i(\mu_{1i} + 2\mu_{2i}) + x_i(\mu_{2i} - \mu_{1i})}{6a_i} - F_{iy} + F_{iz}(a_i - x_i) - F_{ix}(b_i - z_i(x_i)) \right] \\ z_i(0) = 0 \\ z_i'(0) = \sqrt{\mu_{1i}^2 - 1} \end{cases} \quad (3.14)$$

Observasi ini menggunakan pendekatan numerik yang dikenal sebagai metode Runge–Kutta untuk menyelesaikan masalah ini. Faktor gaya  $F_{ix}$ ,  $F_{iy}$ , dan  $F_{iz}$  untuk elemen diskrit  $i$  bergantung pada deformasi balok yang dipelajari dan gaya nodal yang diterapkan  $f_{ix}$ ,  $f_{iy}$ , dan  $f_{iz}$ . Secara konkret, untuk elemen diskrit  $i$ ,  $F_{ix}$  sama dengan jumlah gaya horizontal terpusat  $f_{ix}$  hingga  $f_{nx}$ ;  $F_{iz}$  sama dengan jumlah gaya vertikal terpusat  $f_{iz}$  hingga  $f_{nz}$ , serta berat sendiri elemen diskrit  $(i + 1)$  hingga  $n$ ;  $F_{iy}$  sama dengan momen yang disebabkan oleh berat sendiri, serta gaya terpusat yang diterapkan pada elemen diskrit  $(i + 1)$  hingga  $n$ . Hal ini dapat dinyatakan sebagai berikut:

$$F_{ix} = \sum_{k=i}^n f_{kx} \quad (3.15)$$

$$F_{iz} = f_{iz} + \sum_{k=i+1}^n \left[ f_{kz} + \frac{qa_k(\mu_{1k} + \mu_{2k})}{2} \right] \quad (3.16)$$

$$F_{iy} = f_{iy} + \sum_{k=i+1}^n \left[ f_{ky} + f_{kx} \cdot \sum_{p=i+1}^k b_p - f_{kz} \cdot \sum_{p=i+1}^k a_p \right] - qa_k \mu_{1k} \left( -\frac{a_k}{2} + \sum_{p=i+1}^k a_p \right) - qa_k \frac{\mu_{2k} - \mu_{1k}}{2} \left( -\frac{a_k}{3} + \sum_{p=i+1}^k a_p \right) \quad (3.17)$$

Studi model balok kantilever dimodifikasi menjadi masalah identifikasi variabel  $\mu_{1i}$ ,  $\mu_{2i}$ , dan  $a_i$ ,  $b_i$  untuk keadaan kesetimbangan balok kantilever dengan diberikan nilai  $f_{ix}$ ,  $f_{iy}$ , dan  $f_{iz}$ .

### **Metode Runge–Kutta**

Menyelesaikan ekspresi bentuk tertutup  $z_i(x_i)$  dengan Persamaan (3.12), yang merupakan persamaan diferensial orde kedua yang kompleks, masih merupakan tugas yang sulit. Untuk menyelesaikan solusi tersebut, kurva deformasi elemen diskrit ditentukan menggunakan pendekatan integrasi numerik yang dikenal sebagai pendekatan Runge–Kutta. Untuk menyelesaikan masalah nilai awal persamaan diferensial biasa, pendekatan Runge–Kutta telah diverifikasi sebagai prosedur yang efektif dan akurat. Lebih lanjut, hal ini cukup untuk menyelesaikan persamaan diferensial orde tinggi; namun, metodologi khusus diperlukan untuk mengubah masalah asli menjadi masalah nilai awal dari himpunan persamaan diferensial orde pertama. Secara umum, himpunan persamaan diferensial orde kedua sebagai masalah nilai awal dapat dinyatakan sebagai:

$$\begin{cases} z'' = f(x, z, z') \\ z(x_0) = z_0 \\ z'(x_0) = z'_0 \end{cases} \quad (3.18)$$



Masalah ini dapat diubah menjadi masalah nilai awal dari himpunan persamaan diferensial orde pertama dengan menambahkan variabel baru  $w = z'$  yang dinyatakan sebagai:

$$\begin{cases} z' = w \\ w' = f(x, z, w) \\ z(x_0) = z_0 \\ z'(x_0) = z'_0 \end{cases} \quad (3.19)$$

Pendekatan Runge-Kutta orde keempat dianggap efisien dan akurat untuk menyelesaikan masalah-masalah yang dapat dirumuskan sebagai berikut:

$$\begin{cases} z_{n+1} = z_n + \Delta_x w_n + \frac{\Delta_x^2}{6} (K_1 + K_2 + K_3) \\ w_{n+1} = w_n + \frac{h}{6} (K_1 + 2K_2 + 2K_3 + K_4) \\ K_1 = f(x_n, z_n, w_n) \\ K_2 = f\left(x_n + \frac{\Delta_x}{2}, z_n + \frac{\Delta_x}{2} w_n, w_n + \frac{\Delta_x}{2} K_1\right) \\ K_3 = f\left(x_n + \frac{\Delta_x}{2}, z_n + \frac{\Delta_x}{2} w_n + \frac{\Delta_x^2}{4} K_1, w_n + \frac{\Delta_x}{2} K_2\right) \\ K_4 = f\left(x_n + \Delta_x, z_n + \Delta_x w_n + \frac{\Delta_x^2}{2} K_2, w_n + \Delta_x K_3\right) \end{cases} \quad (3.20)$$

di mana  $\Delta_x$  adalah panjang langkah integral, yaitu, peningkatan koordinat  $x$  selama prosedur integrasi, yang besarnya akan memengaruhi ketelitian hasil integrasi. Sebelum proses integrasi, nilai  $\Delta_x$  harus dipilih, dan kemudian integrasi akan dilakukan melalui ekstrapolasi, dimulai dari titik yang diketahui di mana nilai  $z$  dan  $w$  diketahui. Untuk menghitung kurva deformasi elemen diskrit dari Persamaan (3.14), metode Runge–Kutta orde keempat yang dinyatakan oleh Persamaan (3.20) digunakan dalam observasi ini.

#### **Prediksi Deformasi Elemen dan Momen Lentur**

Deformasi dan momen lentur anggota dapat diprediksi menggunakan model ML dengan prosedur berikut:

1. Masukkan dimensi elemen, sifat material, dan kondisi beban.
2. Terapkan  $f_{ix}$ ,  $f_{iy}$ , dan  $f_{iz}$ .
3. Lakukan analisis dengan analisis elemen hingga (FEA).
4. Ekstrak deformasi dan momen lentur untuk setiap elemen.
5. Siapkan dataset, termasuk  $f_{ix}$ ,  $f_{iy}$ , dan  $f_{iz}$ , sebagai input dan deformasi serta momen lentur sebagai output.
6. Latih algoritma WL- $\epsilon$ -TSVM menggunakan dataset yang diperoleh.
7. Dapatkan deformasi elemen diskrit sebagai  $F_{iz}$  sepanjang arah  $z$  dan  $F_{ix}$  sepanjang arah  $x$ .
8. Dapatkan momen lentur node sebagai  $F_i(y)$ .

### 3.4 ANALISIS BALOK KANTILEVER: ANALITIK & ML

#### Menganalisis Balok Kantilever Berdasarkan Teori Analitik

Analisis dilakukan berdasarkan teori analitik menggunakan platform MATLAB. Metode yang diusulkan mengintegrasikan ekspresi rasional orde tinggi untuk mengkarakterisasi deformasi segmen balok secara analitik dan iterasi dilakukan untuk menyajikan hasil analisis dengan mempertimbangkan kompatibilitas deformasi antar segmen balok. Namun, elemen balok umumnya direpresentasikan oleh fungsi bentuk persamaan kuadrat atau linier dalam pendekatan FEA, dan iterasi matriks kekakuan diperlukan untuk analisis deformasi besar.

Oleh karena itu, pendekatan yang diusulkan lebih efektif daripada pendekatan FEA, karena melibatkan lebih sedikit variabel iterasi dan elemen analitik. Perlu disebutkan bahwa karena perbedaan dalam prosedur kesetaraan yang digunakan untuk menangani berat sendiri balok, mungkin ada variasi antara hasil yang diperkirakan oleh kedua pendekatan tersebut. Dalam pendekatan yang diusulkan, berat sendiri segmen balok dianggap sebagai beban terdistribusi dengan variasi linier sepanjang arah horizontal, sedangkan disederhanakan sebagai gaya nodal. Gambar 3.4 menggambarkan balok kantilever dengan panjang 6 m, diameter luar 50 mm, dan ketebalan dinding 4 mm.


Keakuratan teori analitik yang disajikan diverifikasi dengan melakukan FEA dengan mempertimbangkan balok kantilever menggunakan program ABAQUS. ABAQUS adalah alat yang fleksibel untuk FEA karena kemampuannya untuk mendefinisikan proses analisis. Geometri model disimulasikan dalam ABAQUS menggunakan dimensi yang disajikan oleh modul bagian. Komponen balok B32 digunakan untuk mensimulasikan anggota, memungkinkan gaya aksial, geser, dan momen lentur dihitung secara tepat. Material GFRP diatur sebagai elastis linier, dengan  $D = 1850 \text{ kg/m}^3$  dan  $E = 26 \text{ GPa}$  oleh modul properti. Percepatan gravitasi  $g$  diambil sebagai  $10 \text{ N/kg}$  dalam hal berat sendiri berdasarkan modulus beban.

Balok kantilever dikenai tiga kasus pembebanan sebagai berikut:

Kasus I: hanya berat sendiri;

Kasus II: beban terpusat pada penampang N3 dan berat sendiri;

Kasus III: beban terpusat pada penampang N1, N2, dan N3 dan berat sendiri.

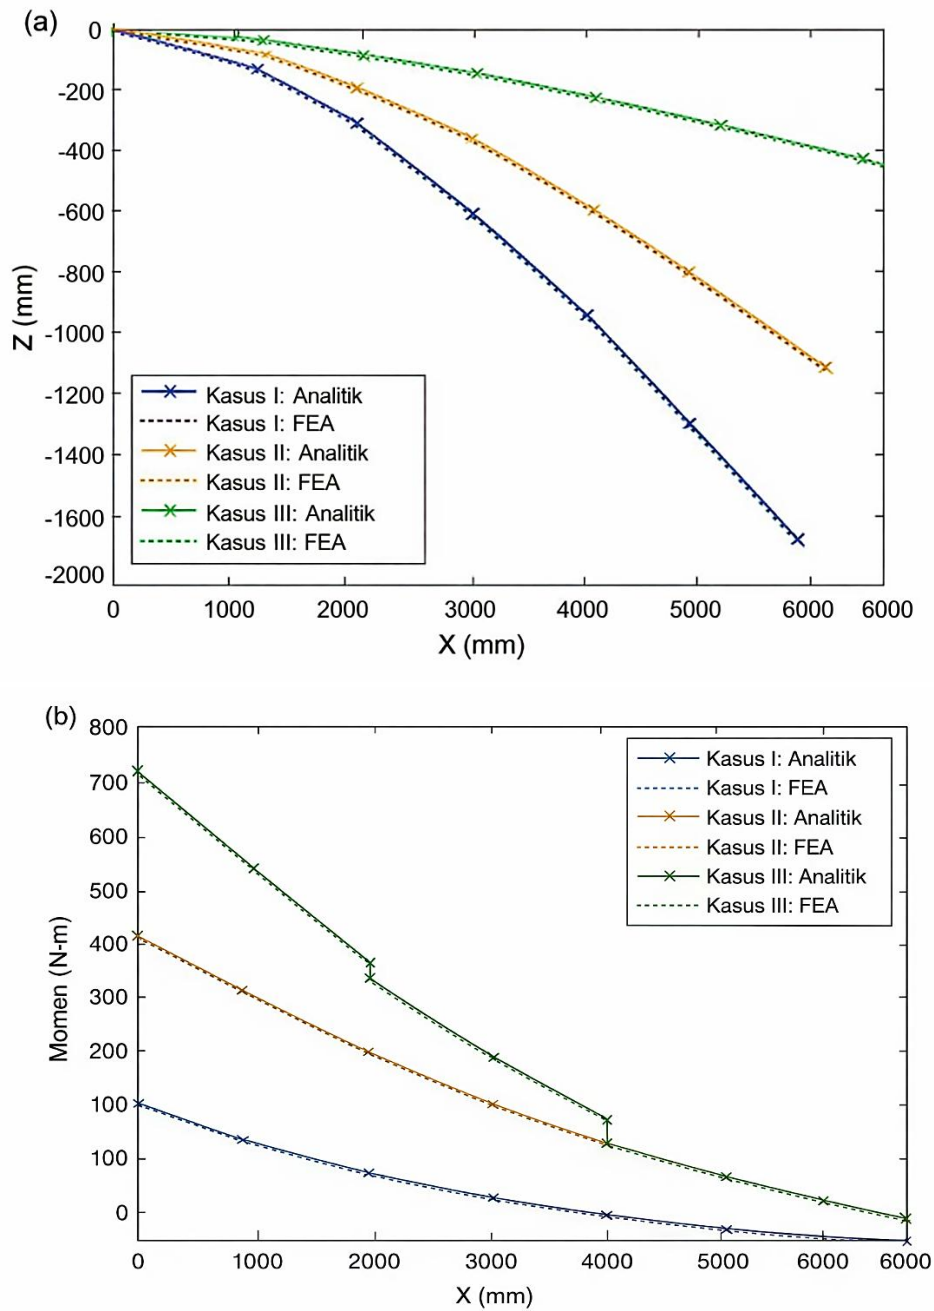


**Gambar 3.4** Detail balok kantilever dan titik-titik pembebanan yang diterapkan.

**Tabel 3.1** Beban Eksternal untuk Berbagai Kasus Beban

	$f_{1x}$ (N)	$f_{1z}$ (N)	$f_{1y}$ (N.m)	$f_{2x}$ (N)	$f_{2z}$ (N)	$f_{2y}$ (N.m)	$f_{3x}$ (N)	$f_{3z}$ (N)	$f_{3y}$ (N.m)
<b>Kasus I</b>	0	0	0	0	0	0	0	0	0
<b>Kasus II</b>	0	0	0	0	0	0	-30	30	-30
<b>Kasus III</b>	-30	-30	-30	-30	-30	-30	-30	30	-30

Gambar 3.4 dan Tabel 3.1 menyajikan titik-titik yang diterapkan dan besaran beban terpusat eksternal.



**Gambar 3.5** Perbandingan balok kantilever: (a) deformasi dan (b) momen lentur.

Gambar 3.5 menunjukkan deformasi dan momen lentur balok kantilever untuk tiga kasus pembebanan. Kurva deformasi dan momen lentur yang dihitung oleh teori analitik yang diberikan ditemukan hampir sama dengan hasil FEA. Tabel 3.2 menunjukkan koordinat z balok ( $z_{end}$ ), koordinat x balok ( $x_{end}$ ), dan momen lentur ( $M_{max}$ ).

Secara umum, perbedaan antara hasil yang dinilai oleh dua pendekatan untuk semua kasus pembebanan lebih kecil dari 1%, menunjukkan bahwa teori yang disajikan cukup tepat.  $z_{end}$  yang dihitung oleh teori yang diusulkan biasanya lebih kecil daripada yang ditentukan oleh FEA, yang diasumsikan terkait dengan asumsi distribusi linier untuk berat sendiri dan pengabaian deformasi geser. Secara keseluruhan, teori analitik yang diusulkan dapat dipraktikkan untuk menganalisis deformasi dan momen lentur balok kantilever yang dikenai gaya terpusat, momen, dan berat sendiri, di mana deformasi geometris yang cukup besar terlibat.


### Analisis Balok Kantilever Berdasarkan Pembelajaran Mesin

Kinerja struktural sampel yang dihasilkan ditentukan menggunakan FEA dengan perangkat lunak ABAQUS. Validitas metode yang disarankan diverifikasi dengan FEA balok kantilever.

**Tabel 3.2** Perbandingan Deformasi dan Momen Lentur

		Kasus I	Kasus II	Kasus III
$z_{end}$ (mm)	FEA	434.0	1205.8	1848.3
	Analitik	431.4	1198.0	1835.6
	Kesalahan	0.60%	0.65%	0.69%
$x_{end}$ (mm)	FEA	5982.0	5853.6	5654.9
	Analitik	5987.5	5860.0	5662.5
	Kesalahan	0.09%	0.11%	0.13%
$M_{max}$ (N.m)	FEA	192.1	431.3	713.9
	Analitik	192.0	431.0	713.3
	Kesalahan	0.03%	0.07%	0.08%

MATLAB juga digunakan untuk membuat model ML, yang memungkinkan pembuatan model dan ekstraksi data secara otomatis, akurat, dan efisien. Gambar 3.6 mengilustrasikan elemen ramping dengan panjang 6 m, ketebalan dinding 4 mm, dan diameter luar 50 mm.



**Gambar 3.6** Detail balok kantilever dan titik-titik beban yang diterapkan.

Elemen balok B32 digunakan untuk anggota; dengan demikian, momen lentur, gaya geser, dan gaya aksial dapat dipertimbangkan. Anggota struktural cangkang grid digambarkan sebagai tabung GFRP melingkar. Karena kinerja linier terdeteksi dalam uji lentur, perilaku elastis linier disimulasikan untuk GFRP dengan mempertimbangkan  $D = 1850 \text{ kg/m}^3$  dan  $E = 26 \text{ GPa}$ . Percepatan gravitasi  $10 \text{ N/kg}$  diambil berdasarkan berat sendiri.

Tujuan dari analisis sampel adalah untuk menyiapkan dataset yang tepat, termasuk enam faktor input ( $f_{1x}, f_{1z}, m_{1y}, f_{2x}, f_{2z}$  dan  $m_{2y}$ ) dan faktor output (deformasi dan momen lentur), untuk melatih dan menguji algoritma karena keberhasilan model ML bergantung pada basis data yang dibangun dengan baik. Tabel 3.3 menunjukkan atribut statistik dari faktor input. Mengubah nilai faktor input menghasilkan balok kantilever yang dikenai kasus beban yang berbeda. Oleh karena itu, 100 sampel disiapkan, dan faktor output diperoleh dengan FEA.

Dengan demikian, tabel dari hasil FEA diekstrak sebagai dataset untuk digunakan pada langkah selanjutnya. Untuk menerapkan model ML, dataset, termasuk 100 sampel, dengan rasio pelatihan 0,9 disiapkan. Sampel pelatihan diimplementasikan untuk membuat model prediksi berdasarkan WL- $\epsilon$ -TSVM dan set pengujian sebagai Kasus I, Kasus II, ..., Kasus X, digunakan untuk menilai akurasi prediksi.

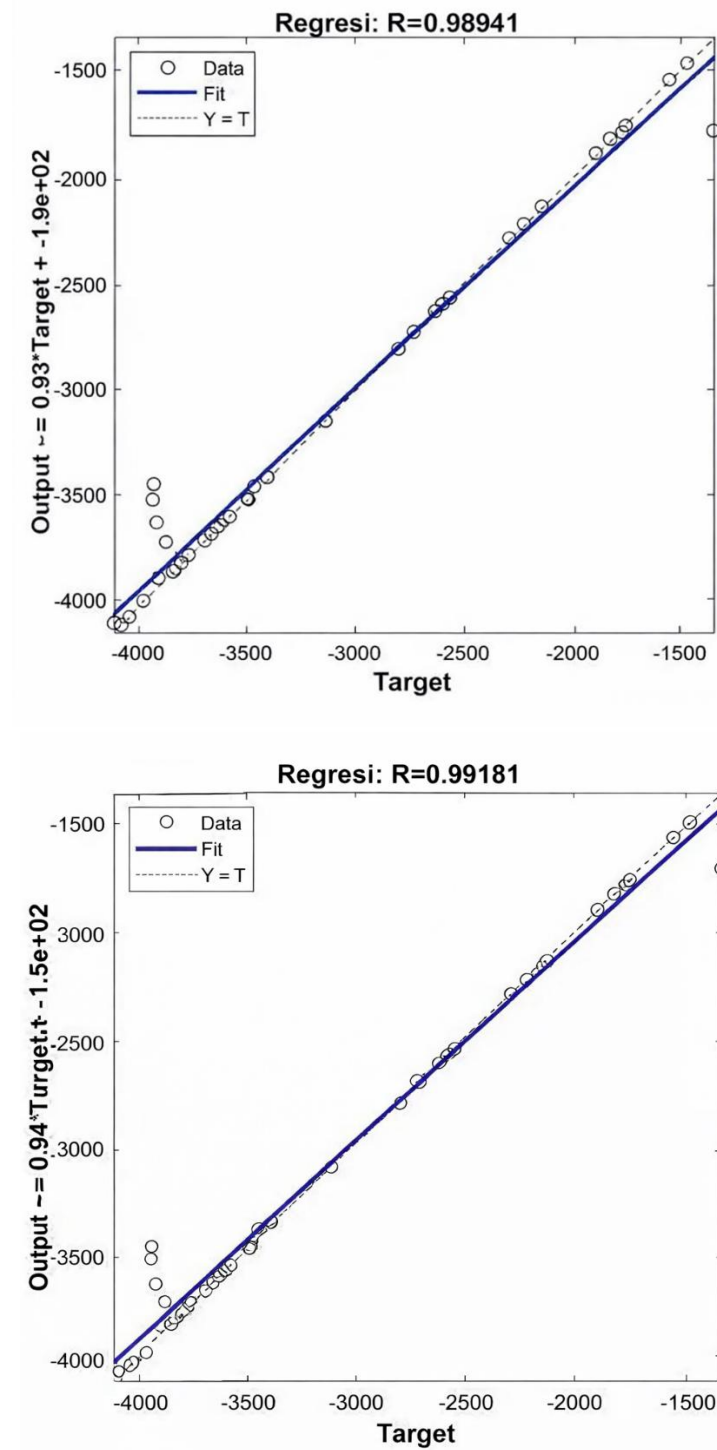
**Tabel 3.3** Atribut Statistik Faktor Masukan

Atribut	Satuan	Minimum	Maksimum	Rata-rata
$f_{1x}$	N	6	60	33
$f_{1z}$	N	-70	-12	-41
$m_{1y}$	N.m	-28	-6	-17
$f_{2x}$	N	6	46	26
$f_{2z}$	N	-60	-2	-31
$m_{2y}$	N.m	-18	-2	-10

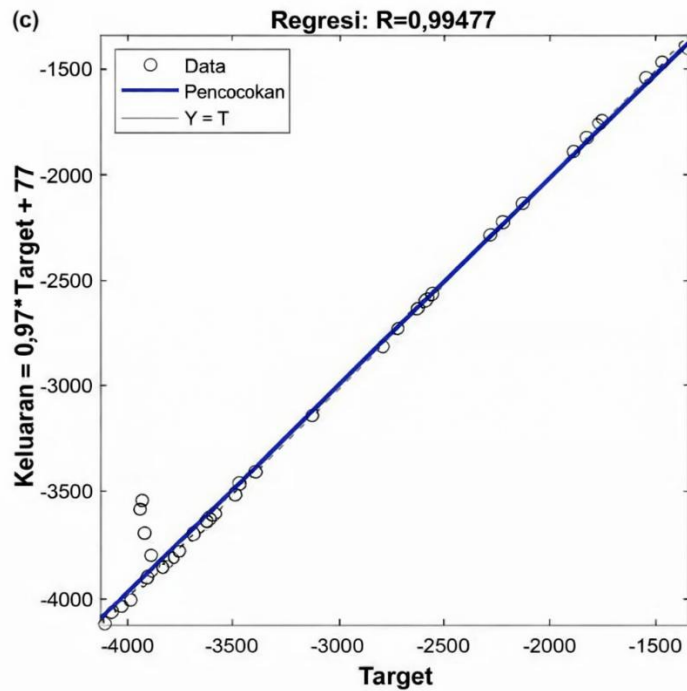
Keberhasilan proses prediksi bentuk sangat bergantung pada prediksi kinerja struktural yang akurat. Tiga algoritma ML, termasuk mesin vektor pendukung nonparalel yang tidak sensitif terhadap parametrik (PIN-SVM), mesin vektor pendukung kembar  $\epsilon$  ( $\epsilon$ -TSVM), dan mesin vektor pendukung kembar Lagrange  $\epsilon$  berbobot (WL- $\epsilon$ -TSVM), dijalankan di platform MATLAB untuk memilih model yang sesuai untuk diimplementasikan dalam proses prediksi bentuk. Oleh karena itu, ketiga model ML ini diterapkan pada dataset yang telah disiapkan dan hasilnya dibandingkan. Gambar 3.7 menampilkan plot regresi dari nilai  $F_3(z)$  sebenarnya dan yang diestimasi. Nilai  $R$  tertinggi dan terendah diperoleh oleh WL- $\epsilon$ -TSVM (0.99477) dan PIN-SVM (0.98941), masing-masing.

Algoritma yang disajikan digunakan untuk memprediksi tiga output, dan nilai *root mean square error* (RMSE) dan  $R$  dari algoritma tersebut diberikan pada Tabel 3.4. Nilai RMSE terendah sebesar 93.72, 48.20, dan 0.0280 untuk  $F_3(z)$ ,  $F_3(x)$ , dan  $F_3(y)$ , masing-masing, diperoleh oleh model WL- $\epsilon$ -TSVM yang menunjukkan akurasi algoritma ini yang lebih tinggi. Nilai  $R$  tertinggi untuk analisis regresi keluaran deformasi pertama, kedua, dan ketiga diperoleh oleh WL- $\epsilon$ -TSVM masing-masing sebesar 0.99477, 0.99637, dan 0.99542. Dapat

dilihat bahwa nilai  $R$  dari algoritma WL- $\epsilon$ -TSVM lebih dekat ke 1 daripada algoritma prediksi lainnya, menunjukkan bahwa WL- $\epsilon$ -TSVM memprediksi keluaran dengan akurasi tertinggi dalam proses prediksi bentuk.



**Gambar 3.7** Plot regresi  $F_3(z)$  yang diperoleh dengan: (a) PIN-SVM; (b)  $\epsilon$ -TSVM; dan (c) WL- $\epsilon$ -TSVM. (Bersambung)



**Gambar 3.7 (Lanjutan)**

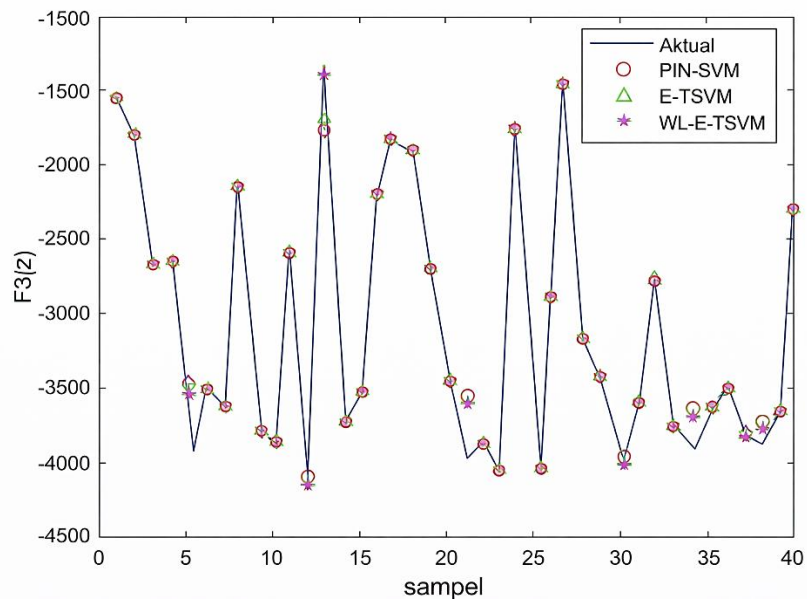
**Tabel 3.4** Indeks Kinerja PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -ETSVM

	RMSE			R		
	$F_3(z)$	$F_3(x)$	$F_3(y)$	$F_3(z)$	$F_3(x)$	$F_3(y)$
<b>PIN-SVM</b>	134.10	74.02	0.0421	0.98941	0.99144	0.98979
<b><math>\epsilon</math>-TSVM</b>	118.22	63.50	0.0369	0.99181	0.99372	0.99214
<b>WL-<math>\epsilon</math>-TSVM</b>	<b>93.72</b>	<b>48.20</b>	<b>0.0280</b>	<b>0.99477</b>	<b>0.99637</b>	<b>0.99542</b>

Singkatan: RMSE, root mean square error; WL- $\epsilon$ -TSVM; weighted Lagrange- $\epsilon$ -twin support vector machine.

Gambar 3.8 mengilustrasikan perbandingan nilai sebenarnya dan nilai estimasi deformasi sepanjang arah z untuk 40 sampel pengujian oleh model ML yang disebutkan. Secara umum, model WL- $\epsilon$ -TSVM mengungguli pendekatan lain dalam hal estimasi karena nilai estimasi yang ditentukan oleh pendekatan ini lebih dekat dengan nilai sebenarnya. Akibatnya, WL- $\epsilon$ -TSVM mengungguli algoritma lain dalam memprediksi perilaku struktural cangkang grid elastis, dan akan lebih lanjut diimplementasikan dalam proses prediksi bentuk.

Gambar 3.9 menggambarkan plot regresi deformasi dalam arah z dan x serta momen lentur yang terkait dengan  $N_3$  yang diperoleh oleh WL- $\epsilon$ -TSVM. Nilai R terendah dan tertinggi diperoleh dari deformasi pada arah z (0.99477) dan deformasi pada arah x (0.99637), masing-masing.

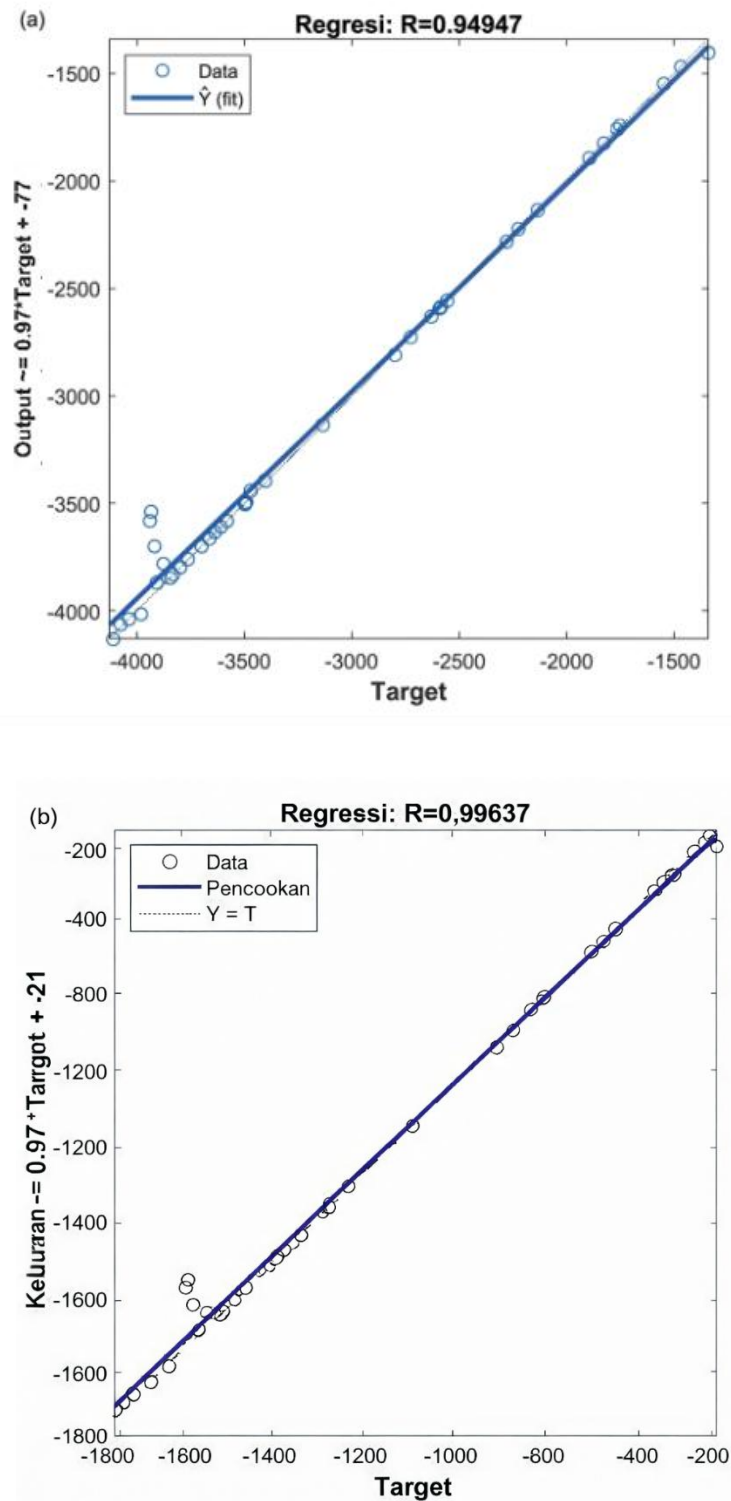


**Gambar 3.8** Perbandingan nilai aktual dan prediksi  $f_3(z)$ .

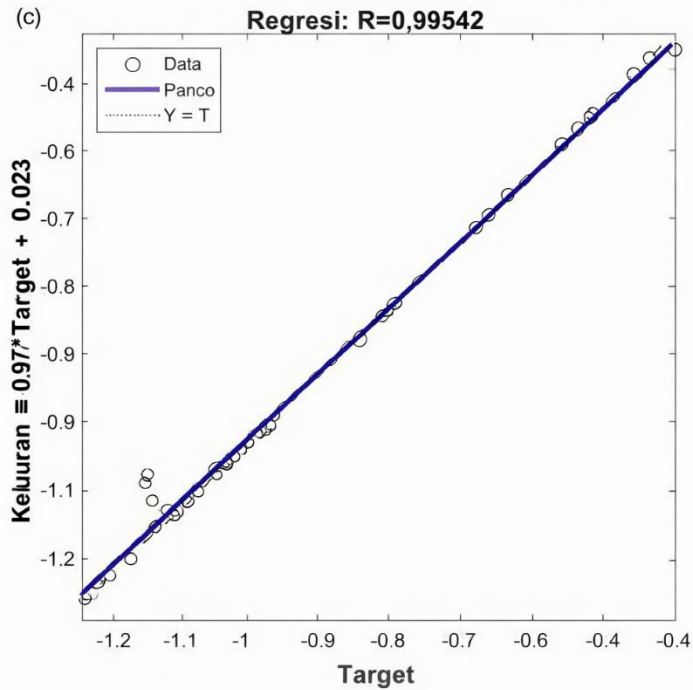
Indikator kinerja disajikan dalam Tabel 3.5, dan nilai terbaik dari setiap indikator ditunjukkan dengan huruf tebal.  $N_1$  mewakili  $R$  tertinggi (0.99600, 0.99683, dan 0.99644) dan NMSE terendah (0.0084, 0.0074, dan 0.0073) untuk tiga output.

Hasil dari tabel menunjukkan bahwa metode yang disajikan dapat memprediksi bentuk balok kantilever dengan akurasi tinggi. Tabel 3.6 dan 3.7 menunjukkan koordinat  $z$  dan  $x$  dari ujung anggota yang diwakili oleh  $z_{end}$  dan  $x_{end}$ , masing-masing. Nilai yang diperoleh oleh algoritma FEA dan ML menunjukkan kesesuaian terbaik pada Kasus II dengan kesalahan relatif 0.02% untuk deformasi pada arah  $z$  dan  $x$ . Selain itu, kesepakatan terburuk diamati pada Kasus VIII, dengan kesalahan relatif sebesar 2.50% dan 3.14% untuk deformasi pada arah  $z$  dan  $x$ , masing-masing. Kesalahan relatif rata-rata sama dengan 0.53% dan 0.79% untuk deformasi pada arah  $z$  dan  $x$ , masing-masing.

Diamati bahwa kurva deformasi yang diperoleh dengan metode yang dijelaskan hampir setara dengan hasil FEA. Tabel 3.8 menyajikan perbandingan momen lentur yang diperoleh dengan FEA dan WL- $\epsilon$ -TSVM. Kinerja terbaik terkait dengan Kasus I, sedangkan kinerja terburuk terkait dengan Kasus VIII. Kesalahan relatif rata-rata sama dengan 0.7% untuk prediksi momen lentur balok kantilever.



Gambar 3.9 Plot regresi  $n_3$ : (a)  $f_3(z)$ ; (b)  $f_3(x)$ ; dan (c)  $f_3(y)$ . (Lanjutan)



**Gambar 3.9 (Lanjutan)**

**Tabel 3.5 Indikator Kinerja**

	ARD	NMSE	RMSE	SD	R
<b>Koordinat z</b>					
N <sub>1</sub>	-0.5397	0.0084	21.2849	0.0221	0.99600
N <sub>2</sub>	-0.4654	0.0101	55.0735	0.0251	0.99557
N <sub>3</sub>	-0.6042	0.0119	93.7156	0.0252	0.99477
<b>Koordinat x</b>					
N <sub>1</sub>	0.0771	0.0074	8.8435	0.0611	0.99683
N <sub>2</sub>	0.0131	0.0077	27.2716	0.0757	0.99668
N <sub>3</sub>	-0.1211	0.0084	48.2026	0.0551	0.99637
<b>Momen Lentur</b>					
N <sub>1</sub>	-0.1116	0.0073	13.2253	0.0979	0.99644
N <sub>2</sub>	-2.7334	0.0230	60.2621	0.0735	0.98980
N <sub>3</sub>	-0.4674	0.0105	0.0280	0.0278	0.99542

Singkatan: ARD, deviasi relatif rata-rata; NMSE, kesalahan kuadrat rata-rata ternormalisasi; SD, deviasi standar.

**Tabel 3.6 Perbandingan Deformasi N<sub>3</sub> pada arah z**

Kasus	z End (mm)			
	FEA	WL-e-TSVM	Error	Error Relatif
Kasus I	-2281.06	-2281.49	-0.43	0.02%
Kasus II	-2557.57	-2557.01	0.56	0.02%
Kasus III	-2798.45	-2809.20	-10.75	0.38%
Kasus IV	-3471.11	-3439.90	31.21	0.90%
Kasus V	-3497.38	-3503.68	-6.30	0.18%
Kasus VI	-3637.34	-3634.68	2.66	0.07%

<b>z End (mm)</b>				
<b>Kasus</b>	<b>FEA</b>	<b>WL-e-TSVM</b>	<b>Error</b>	<b>Error Relatif</b>
Kasus VII	-3763.41	-3758.47	4.94	0.13%
Kasus VIII	-3877.51	-3780.51	97.00	2.50%
Kasus IX	-3981.19	-4014.43	-33.24	0.83%
Kasus X	-4075.76	-4065.38	10.38	0.25%

Singkatan: FEA, analisis elemen hingga; WL- $\epsilon$ -TSVM, mesin vektor pendukung kembar Lagrange- $\epsilon$  berbobot.

**Tabel 3.7** Perbandingan Deformasi  $N_3$  pada arah  $x$

<b>x Ujung (mm)</b>				
	<b>FEA</b>	<b>WL-e-TSVM</b>	<b>Error</b>	<b>Error Relatif</b>
Kasus I	-491.57	-492.00	-0.43	0.09%
Kasus II	-626.64	-626.78	-0.14	0.02%
Kasus III	-760.61	-768.37	-7.76	1.02%
Kasus IV	-1206.17	-1186.87	19.30	1.60%
Kasus V	-1224.92	-1230.33	-5.41	0.44%
Kasus VI	-1341.00	-1339.90	1.10	0.08%
Kasus VII	-1452.37	-1450.17	2.20	0.15%
Kasus VIII	-1559.10	-1510.08	49.02	3.14%
Kasus IX	-1661.32	-1678.11	-16.79	1.01%
Kasus X	-1759.20	-1753.32	5.88	0.33%


Singkatan: FEA, analisis elemen hingga; WL- $\epsilon$ -TSVM, mesin vektor pendukung kembar Lagrange- $\epsilon$  berbobot.

Gambar 3.10 menunjukkan perbandingan momen lentur aktual dan prediksi balok kantilever. Secara umum, hasilnya menunjukkan bahwa metode yang disarankan akurat dan praktis untuk prediksi bentuk batang ramping yang dikenai berat sendiri.

**Tabel 3.8** Perbandingan Momen Lentur  $N_3$  untuk Balok Kantilever

<b>Momen Lentur (N.m)</b>				
	<b>FEA</b>	<b>WL-e-TSVM</b>	<b>Error</b>	<b>Error Relatif</b>
Kasus I	-0.62225	-0.62224	0.00002	0.00%
Kasus II	-0.72145	-0.72136	0.00009	0.01%
Kasus III	-0.81245	-0.81582	-0.00337	0.41%
Kasus IV	-1.03893	-1.02201	0.01692	1.63%
Kasus V	-0.93400	-0.94343	-0.00943	1.01%
Kasus VI	-1.00294	-1.00120	0.00174	0.17%
Kasus VII	-1.06656	-1.06526	0.00130	0.12%
Kasus VIII	-1.12530	-1.09682	0.02848	2.53%
Kasus IX	-1.17960	-1.18938	-0.00978	0.83%
Kasus X	-1.22984	-1.22628	0.00356	0.29%

Singkatan: FEA, analisis elemen hingga; WL- $\epsilon$ -TSVM, mesin vektor pendukung kembar Lagrange- $\epsilon$  berbobot.



**Gambar 3.10** Perbandingan momen lentur aktual dan prediksi balok kantilever.

### 3.5 PREDIKSI DEFORMASI BALOK DENGAN WL- $\epsilon$ -TSVM

Bab ini memperkenalkan dua kerangka kerja untuk menganalisis balok ramping selama prosedur konstruksi pengangkatan, satu berdasarkan teori analitik dan yang lainnya berdasarkan metode ML. Teori analisis elemen diskrit untuk balok diturunkan dan divalidasi melalui contoh numerik. Selain itu, kinerja tiga model ML, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM, dibandingkan untuk menganalisis elemen ramping, dengan model WL- $\epsilon$ -TSVM menunjukkan hasil yang lebih unggul. Nilai  $R$  analisis regresi tertinggi untuk  $F_3(z)$ ,  $F_3(x)$ , dan  $F_3(y)$  masing-masing adalah 0.99477, 0.99637, dan 0.99542, yang dicapai oleh model WL- $\epsilon$ -TSVM. Akibatnya, model ini digunakan untuk menganalisis anggota yang diangkat tunggal dengan deformasi geometris yang signifikan. Metode ini selanjutnya divalidasi menggunakan FEA, yang mengkonfirmasi kepraktisan dan akurasinya. Pendekatan ini terbukti tepat dan efektif untuk menganalisis elemen yang diangkat, menawarkan wawasan berharga dalam memperkirakan deformasi dan momen lentur pada elemen ramping selama proses pengangkatan, terutama ketika terjadi deformasi geometris yang besar. Yang penting, metode prediktif yang dibahas dalam bab ini memberikan alternatif yang efisien untuk FEA yang memakan waktu dalam mengevaluasi deformasi dan momen lentur elemen ramping.

## **BAB 4**

### **PREDIKSI BENTUK GRIDSHELL GFRP SAAT PENGANGKATAN**

#### **4.1 KEMAJUAN PREDIKSI BENTUK GRIDSHELL GFRP**

Struktur ruang telah banyak digunakan dalam beberapa dekade terakhir karena kemampuannya untuk menutupi bentang yang besar dengan berat sendiri yang relatif lebih ringan. Berbagai bentuk struktur ringan, seperti kisi baja, membran, dan struktur kabel, telah mengalami kemajuan signifikan selama periode ini, memungkinkan penerapannya secara luas dalam proyek arsitektur dan teknik. Di antara struktur-struktur ini, gridshell elastis, yang dicirikan oleh nonlinieritas geometrisnya, telah menjadi fokus observasi, khususnya dalam hal prediksi bentuknya selama proses konstruksi. Prediksi bentuk yang akurat sangat penting karena kinerja struktural gridshell ini sangat dipengaruhi oleh konfigurasi geometrisnya selama pemasangan. Selama dekade terakhir, beberapa observasi telah berkonsentrasi pada karakteristik struktural, metodologi desain, dan teknik konstruksi gridshell elastis polimer yang diperkuat serat kaca (GFRP).

Beberapa peneliti telah berkontribusi untuk memahami dan mengoptimalkan perilaku struktural gridshell elastis. Vault mengembangan alat numerik untuk mensimulasikan proses pencarian bentuk menggunakan batang elastis diskrit, sementara Hernandez dkk. mengusulkan teknik optimasi nonlinier untuk meningkatkan topologi gridshell. Studi lain, seperti yang dilakukan oleh Changyeob dan Pedro dan Mesnil dkk., mengeksplorasi pengaruh kekakuan anggota, kepadatan grid, dan prategangan pada kinerja struktural gridshell. Selain itu, Tayeb dkk. mendemonstrasikan kinerja daktil gridshell selama keruntuhan, dan Fernandes dkk. memberikan wawasan tentang pendekatan pemasangan yang efektif. Selain itu, pemodelan informasi bangunan (BIM) dan teknik optimasi juga telah memainkan peran transformatif dalam desain dan konstruksi struktural.

Lebih jauh lagi, kemajuan terbaru dalam kecerdasan buatan (AI) dan pembelajaran mesin (ML) telah menunjukkan potensi dalam mengatasi tantangan yang terkait dengan metode prediksi bentuk tradisional. Teknologi ini menyediakan solusi yang andal untuk menangani masalah rekayasa yang kompleks, seperti ketidakpastian dan variabilitas dalam perilaku struktural. Model ML dapat membantu memprediksi bentuk struktural dan gaya internal secara akurat selama proses konstruksi dengan memanfaatkan kumpulan data konfigurasi gridshell. Hal ini tidak hanya mengurangi waktu dan upaya yang dibutuhkan untuk eksperimen tetapi juga meningkatkan efisiensi pengambilan keputusan, meminimalkan kesalahan, dan kinerja struktural secara keseluruhan.


## 4.2 ANALISIS DISKRIT & PREDIKSI DEFORMASI PENGANGKATAN

### Interaksi Antar Anggota

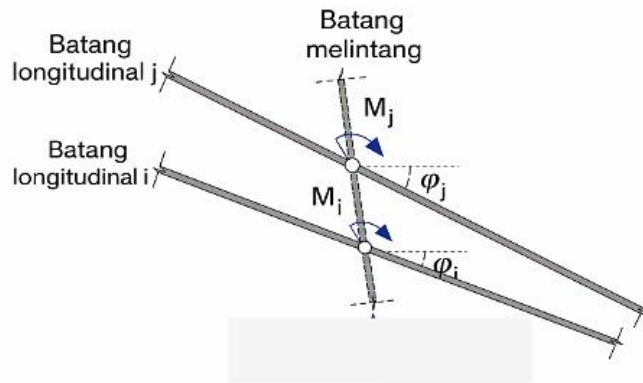
Elemen struktural dianalisis secara individual menggunakan teknik yang direkomendasikan, sementara kompatibilitas deformasi yang dibutuhkan oleh dampak grid harus dikonfirmasi. Koordinat titik-titik yang terhubung pada elemen yang berpotongan diharapkan sama untuk setiap simpul grid. Selanjutnya, dampak interaksi gaya nodal harus dipertimbangkan untuk mendapatkan bentuk deformasi grid. Misalnya, resultan beban nodal vertikal harus secara matematis setara dengan gravitasi tetapi dalam arah yang berlawanan.

Selanjutnya, asumsi berikut diberikan dalam proses prediksi bentuk yang ditawarkan mengenai efek interaksi antar elemen. Deformasi horizontal komponen dapat dihitung secara independen dari deformasi vertikalnya. Deformasi vertikal elemen jauh lebih tinggi daripada deformasi horizontalnya. Akibatnya, pemisahan perhitungan deformasi horizontal dan vertikal masuk akal selama analisis. Deformasi horizontal elemen dapat diperkirakan dengan cukup akurat jika objek observasi adalah elemen dengan deformasi vertikal. Studi ini bertujuan untuk menyelesaikan deformasi elemen horizontal sebagai balok lurus, dengan panjang yang identik dengan proyeksi horizontal elemen, dan penampang balok setara dengan elemen struktural. Gambar 4.1 mengilustrasikan deformasi horizontal elemen struktural yang dapat dihitung menggunakan pendekatan yang disajikan, dengan mempertimbangkan gaya nodal horizontal. Perlu dicatat bahwa resultan beban horizontal untuk setiap elemen harus nol.

Selanjutnya, momen terkonsentrasi pada persimpangan elemen sebanding dengan sudut vertikal antara elemen paralel. Karena konektor perancah putar membatasi rotasi di luar bidang antara elemen, efek torsi ada pada elemen struktural yang menghasilkan momen lentur terkonsentrasi pada elemen yang berpotongan. Gambar 4.2 menunjukkan tampilan elevasi dari dua elemen paralel yang dihubungkan oleh elemen transversal. Sudut kemiringan elemen longitudinal  $i$  dan  $j$  digambarkan oleh  $\varphi_i$  dan  $\varphi_j$ , masing-masing. Torsi segmen elemen transversal di antara elemen tersebut menimbulkan sepasang momen terkonsentrasi interaksi ( $M_i$  dan  $M_j$ ) pada elemen  $i$  dan  $j$ , seperti yang digambarkan pada Gambar 4.2.



**Gambar 4.1** Model sederhana untuk analisis deformasi horizontal (tampilan atas).




**Gambar 4.2** Momen pada persimpangan elemen.

### Prosedur Konstruksi

Pendekatan konstruksi untuk struktur cangkang kisi elastis merupakan topik yang sangat penting. Proses pengangkatan dan pemasangan merupakan metodologi sederhana dan praktis yang sering menggunakan kabel dan derek. Selama proses pemasangan, kabel awalnya dihubungkan ke kait derek dan kisi datar, kemudian kisi diangkat dan dideformasi secara elastis. Karena kerusakan elemen kayu sering terjadi di sekitar simpul kabel yang terhubung, pendekatan yang hemat waktu dan mudah ini belum banyak diadopsi pada cangkang kisi kayu. Namun, pendekatan ini telah diterapkan dalam berbagai proyek teknik untuk keandalan dan kekuatan material GFRP yang jauh lebih tinggi, membuktikan efisiensi, keamanan, dan kesederhanaannya.

Strategi konstruksi pengangkatan untuk kubah barel disajikan, dengan mempertimbangkan simetri cangkang kisi tersebut. Balok pengangkat digunakan dan ditempatkan di bawah grid untuk menopang selama prosedur pengangkatan, seperti yang ditunjukkan pada Gambar 4.3. Balok pengangkat harus dipasang pada garis grid simetris sepanjang gridshell, dan kabel harus dihubungkan langsung ke elemen pengangkat.



**Gambar 4.3** Proses pengangkatan struktur cangkang kisi elastis kubah barel.

Jumlah dan lokasi simpul pengangkat harus ditentukan, dengan mempertimbangkan kekakuan lentur balok pengangkat, untuk memberikan kelurusan balok yang memuaskan selama pemasangan pengangkatan. Dalam pendekatan ini, balok pengangkat dianggap sebagai batang kaku; oleh karena itu, deformasi grid dalam keadaan terangkat dapat disederhanakan menjadi masalah planar. Perlu dicatat bahwa massa tambahan biasanya dihubungkan secara merata sepanjang gridshell untuk mengontrol bentuk deformasi dan akibatnya mempermudah pemasangan penyangga karena bentuk deformasi gridshell dalam keadaan terangkat mungkin berbeda dari bentuk target. Massa tambahan dapat ditambahkan ke model yang disederhanakan dengan menetapkan beban terpusat ke bawah.

Karena deformasi horizontal elemen jauh lebih kecil daripada deformasi vertikal, analisis deformasi untuk setiap elemen dapat secara kasar dianggap sebagai masalah bidang. Kisi dua lapis digantung dan mengalami deformasi vertikal akibat berat sendiri, seperti yang diilustrasikan pada Gambar 4.4. Elemen struktural terdistorsi akibat gaya nodal dan gravitasi. Hanya gaya terpusat vertikal yang bekerja pada bagian tengah karena simetri; namun, gaya vertikal dan horizontal serta momen lentur adalah gaya nodal umum, seperti yang ditunjukkan pada Gambar 4.4.



**Gambar 4.4** Sebuah elemen dalam struktur cangkang kisi.

Berdasarkan model elemen diskrit, model ML dijelaskan untuk mengevaluasi model masalah bidang tersebut pada bagian berikut, dan berdasarkan itu, pendekatan prediksi bentuk disajikan untuk memprediksi deformasi kisi di bawah pengangkatan.

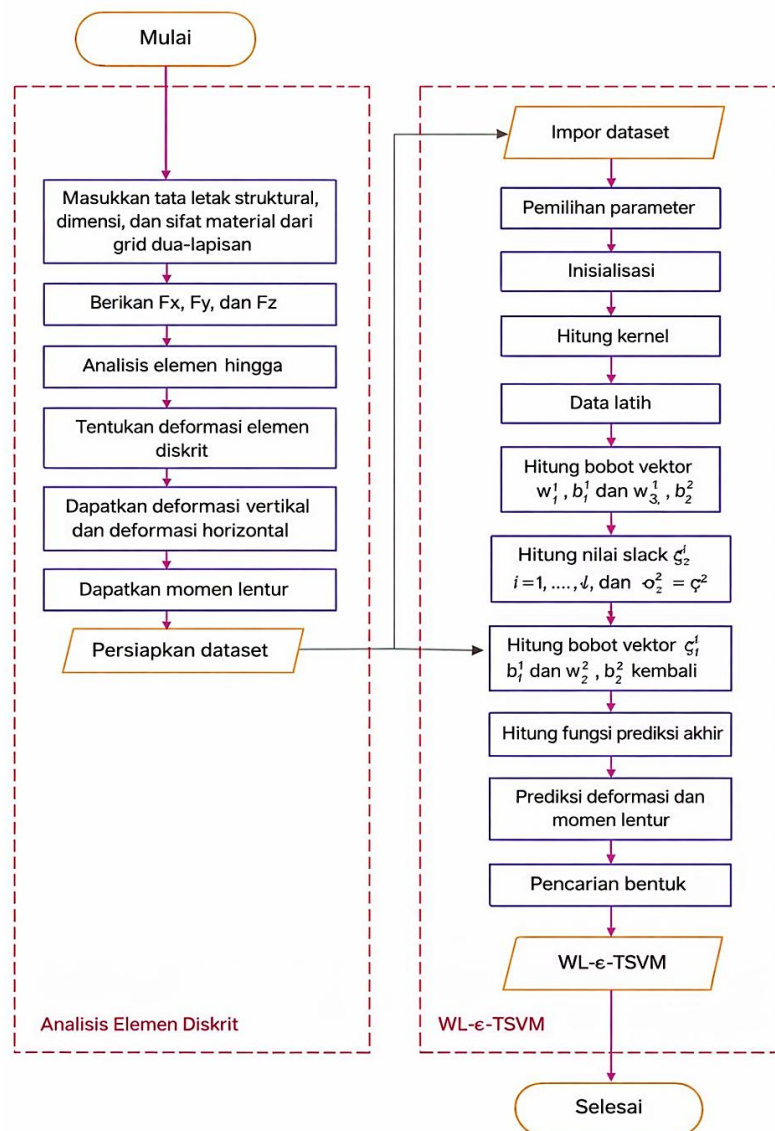
#### **Prediksi Deformasi Elemen Dan Momen Lentur**

Deformasi dan momen lentur elemen gridshell dapat diprediksi menggunakan model ML dengan prosedur berikut:

1. Masukkan dimensi struktur, sifat material, dan kondisi beban.
2. Terapkan  $f_{ix}$ ,  $f_{iy}$ , dan  $f_{iz}$ .
3. Lakukan analisis dengan analisis elemen hingga (FEA).
4. Ekstrak deformasi dan momen lentur untuk setiap elemen.
5. Siapkan dataset, termasuk  $f_{ix}$ ,  $f_{iy}$ , dan  $f_{iz}$ , sebagai input dan deformasi serta momen lentur sebagai output.

6. Latih algoritma weighted Lagrange  $\epsilon$ -twin support vector machine (WL- $\epsilon$ -TSVM) menggunakan dataset yang diperoleh.
7. Dapatkan deformasi elemen gridshell sebagai  $F_1(z)$ , sepanjang arah  $z$  dan  $F_1(x)$ , sepanjang arah  $x$ .
8. Dapatkan momen lentur node sebagai  $F_1(y)$ .

Oleh karena itu, teknik prediksi bentuk untuk mengevaluasi deformasi dan momen lentur grid selama pengangkatan ditawarkan berdasarkan pendekatan yang disajikan. Gambar 4.5 mengilustrasikan diagram alir proses prediksi bentuk. Pendekatan yang diberikan dibagi menjadi dua bagian: analisis elemen diskrit dan model ML, seperti yang ditunjukkan pada Gambar 4.5. Kumpulan nilai utama beban nodal harus disiapkan untuk model ML. Model ML dilatih dengan mempertimbangkan gaya nodal sebagai input. Pendekatan yang disajikan dilakukan dengan bahasa komputasi ilmiah MATLAB karena kemudahannya dalam pemrograman.



**Gambar 4.5** Diagram alir proses prediksi bentuk.

### **4.3 CONTOH NUMERIK DARI KUBBAH TONG**


#### **Informasi Struktural**

Berdasarkan model sederhana dari elemen transversal, teknik ML diterapkan untuk memperkirakan deformasi dan momen lentur kubah tong elastis. Sistem struktural kubah tong ditunjukkan pada Gambar 4.6, di mana sistem penguat elemen dan sistem penguat kabel dipasang. Setelah deformasi lentur, grid elastis pertama kali dipasang pada penyangga, seperti yang ditunjukkan pada Gambar 4.6. Menghubungkan lapisan elemen kontinu panjang diagonal ke gridshell menghasilkan gridshell tiga lapis dengan jaring segitiga yang stabil. Sebagai alternatif, gridshell hibrida stabil akhir yang terbuat dari elemen kontinu panjang dan kabel dapat dibuat dengan memperkuat grid elastis dengan kabel silang.

Sebuah dataset yang mencakup enam faktor input ( $f_{1x}$ ,  $f_{1z}$ ,  $m_{1y}$ ,  $f_{2x}$ ,  $f_{2z}$ , dan  $m_{2y}$ ) dan faktor output (deformasi dan momen lentur) disiapkan untuk pelatihan dan pengujian algoritma WL- $\epsilon$ -TSVM. Mengubah nilai faktor input menghasilkan elemen ramping dan struktur kubah barel yang dikenai berbagai kasus beban. Dalam observasi ini, 200 sampel dipertimbangkan dan dikenai berbagai kasus beban, termasuk 160 analisis elemen ramping sebagai set pelatihan dan 40 elemen kubah barel sebagai set pengujian. Sepuluh kasus dari set pengujian yang dikenai berbagai kasus beban disajikan sebagai Kasus I, Kasus II, ..., Kasus X untuk deskripsi rinci dalam bab ini. Perlu dicatat bahwa set pelatihan disiapkan dengan menganalisis elemen diskrit, sedangkan set pengujian disediakan dengan menganalisis struktur cangkang kisi kubah barel. Kisi-kisi tersebut memiliki panjang 30 m dan lebar 24 m, dengan ukuran kisi 2 m.

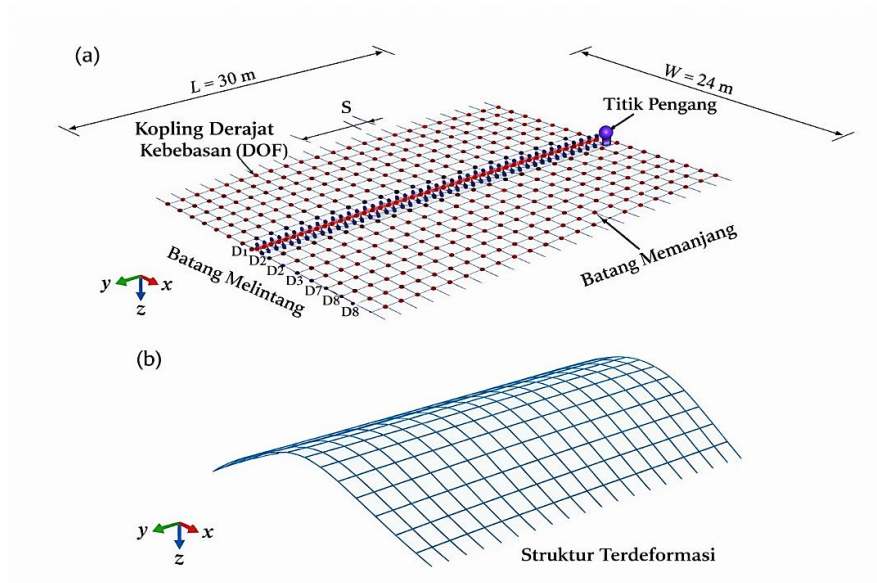
#### **Model Elemen Hingga**

Perangkat lunak ABAQUS digunakan untuk menentukan deformasi dan momen lentur cangkang kisi. Simulasi kisi dua lapis diilustrasikan pada Gambar 4.7. Elemen GFRP pultruded pertama kali dimodelkan dengan membuat elemen secara terpisah sepanjang arah  $x$  dan  $y$  dengan radius luar 25 mm dan ketebalan dinding 4 mm, menggunakan elemen balok B32 di ABAQUS. Penampang model ditentukan oleh alat pengelola penampang di modul properti. Material GFRP diatur sebagai elastis linier, dengan  $D = 1850 \text{ kg/m}^3$  dan  $E = 26$  oleh alat pengelola material di modul properti. Untuk memodelkan efek dukungan yang diberikan oleh elemen pengangkat selama prosedur pengangkatan, perpindahan nodal ke atas diimplementasikan ke semua titik elemen longitudinal pusat oleh modul beban dalam perangkat lunak, seperti yang ditunjukkan pada Gambar 4.7a.



**Gambar 4.6** Sistem struktur cangkang kisi elastis kubah barel.

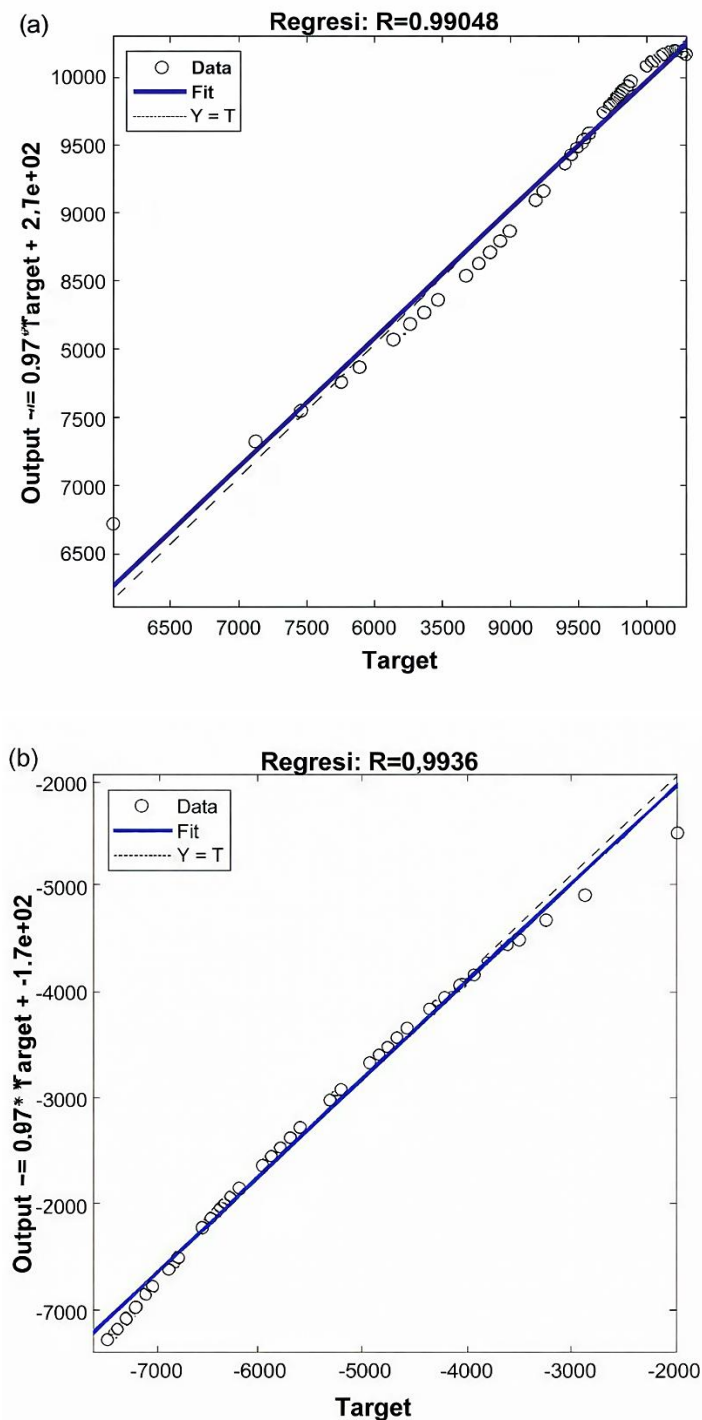
Penggabungan derajat kebebasan (DOF) digunakan dalam analisis elemen hingga (FEA) untuk sambungan elemen, berdasarkan mekanisme struktural konektor perancah putar, yang sering digunakan untuk menyambungkan elemen pada persimpangan anggota dengan modul interaksi. Untuk tujuan ini, dua kelompok node, termasuk node sambungan dari dua lapisan gridshell sepanjang arah  $x$  dan  $y$ , dibuat dan dihubungkan secara terpisah. DOF translasi dan rotasi di luar bidang digabungkan untuk sepasang titik yang terhubung pada setiap persimpangan balok, sedangkan DOF rotasi di dalam bidang tidak terkait. Dalam model, panjang elemen balok dibatasi hingga 250 mm oleh modul mesh. Akhirnya, analisis dilakukan dengan alat pengelola pekerjaan di modul pekerjaan dan hasilnya diperoleh.



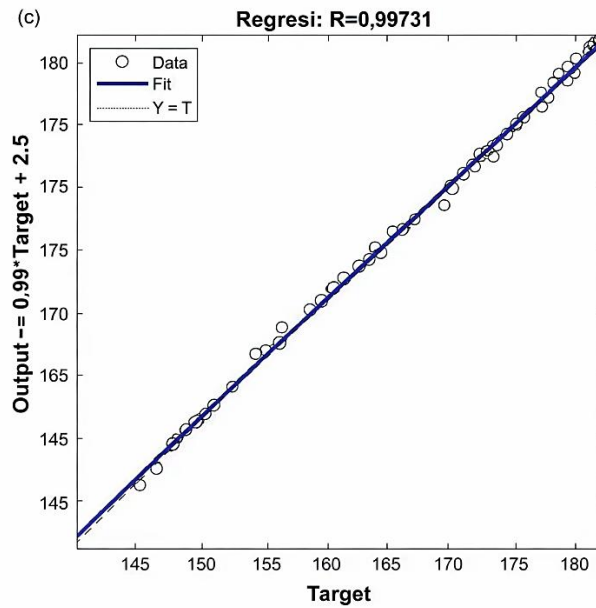
**Gambar 4.7** Simulasi struktur: (a) kisi dua lapis datar dan (b) bentuk yang berubah bentuk.

### Hasil Analisis

Plot regresi deformasi sepanjang arah  $z$  dan  $x$ , serta momen lentur, digambarkan pada Gambar 4.8. Nilai  $R$  terendah dan tertinggi dari sampel pengujian diperoleh oleh deformasi sepanjang arah  $z$  (0.99048) dan momen lentur (0.99731), masing-masing. Perbandingan deformasi dilakukan antara model sederhana yang diperoleh dengan metode yang disajikan dan FEA, seperti yang digambarkan pada Gambar 4.9.




Gambar 4.8 Plot regresi dari: (a)  $f_3(z)$ , (b)  $f_3(x)$ , dan (c)  $f_3(y)$ . (Lanjutan)



Gambar 4.8 (Lanjutan)

Dari Gambar 4.9, dapat diamati bahwa deformasi yang diperkirakan menggunakan metode yang disajikan sangat sesuai dengan yang diperoleh oleh FEA untuk semua kasus. Tabel 4.1 dan 4.2 menunjukkan koordinat  $z$  dan  $x$  dari ujung anggota titik persimpangan.

Dengan membandingkan deformasi, diamati bahwa kesalahan pada koordinat  $z$  dan  $x$  relatif rendah (masing-masing hingga 5,12% dan 5,76%), menunjukkan bahwa metodologi yang disarankan praktis untuk memperkirakan bentuk lentur struktur kubah barel selama pengangkatan dan pemasangan. Momen lentur dari sepuluh kasus disajikan dalam Tabel 4.3.



Gambar 4.9 Perbandingan deformasi aktual dan prediksi elemen kubah barel selama proses pengangkatan dan pemasangan.

**Tabel 4.1** Perbandingan koordinat z untuk Sambungan Kubah Barel

	<b>Z<sub>end</sub> (mm)</b>							
	<b>D<sub>1</sub></b>	<b>D<sub>2</sub></b>	<b>D<sub>3</sub></b>	<b>D<sub>4</sub></b>	<b>D<sub>5</sub></b>	<b>D<sub>6</sub></b>	<b>D<sub>7</sub></b>	<b>D<sub>8</sub></b>
<b>FEA</b>	312.80	1089.55	2132.27	3317.74	4576.91	5871.58	7180.48	8492.70
<b>WL-ε-TSVM</b>	328.82	1083.03	2085.33	3285.89	4605.19	5952.75	7237.33	8377.15
<b>Galat</b>	16.02	-6.52	-46.94	-31.85	28.28	81.17	56.85	-115.55
<b>Galat Relatif</b>	5.12%	0.60%	2.20%	0.96%	0.62%	1.38%	0.79%	1.36%

Singkatan: FEA, analisis elemen hingga; WL-ε-TSVM, mesin vektor pendukung kembar Lagrange-ε berbobot.

Momen lentur elemen transversal yang diperoleh dengan WL-ε-TSVM sesuai dengan yang dihitung dengan FEA, sementara kesalahan relatif maksimum sebesar 4,37% dapat diamati pada Kasus I. Akibatnya, metode yang disarankan dapat secara akurat memperkirakan momen lentur elemen kubah barel. Pendekatan yang diusulkan tampaknya sesuai untuk memprediksi kurva deformasi dan momen lentur anggota dalam grid elastis di bawah proses pengangkatan.

**Tabel 4.2** Perbandingan koordinat x untuk Sambungan Kubah Barel

	<b>X<sub>end</sub> (mm)</b>							
	<b>D<sub>1</sub></b>	<b>D<sub>2</sub></b>	<b>D<sub>3</sub></b>	<b>D<sub>4</sub></b>	<b>D<sub>5</sub></b>	<b>D<sub>6</sub></b>	<b>D<sub>7</sub></b>	<b>D<sub>8</sub></b>
<b>FEA</b>	-43.18	-265.42	-689.84	-1271.97	-1957.21	-2699.78	-3467.13	-4240.43
<b>WL-ε-TSVM</b>	-40.69	-273.98	-700.77	-1276.49	-1963.19	-2713.76	-3477.19	-4204.33
<b>Galat</b>	2.49	-8.56	-10.93	-4.52	-5.98	-13.98	-10.06	36.10
<b>Galat Relatif</b>	5.76%	3.23%	1.58%	0.36%	0.31%	0.52%	0.29%	0.85%

Singkatan: FEA, analisis elemen hingga; WL-ε-TSVM, mesin vektor pendukung kembar Lagrange-ε berbobot.

**Tabel 4.3** Perbandingan Momen Lentur di  $D_1$  untuk Kubah Tong


<b>Kasus</b>	<b>Momen Lentur (N.m)</b>			
	<b>FEA</b>	<b>WL-ε-TSVM</b>	<b>Galat</b>	<b>Galat Relatif</b>
Kasus I	1.41	1.47	0.06	4.37%
Kasus II	1.61	1.62	0.01	0.38%
Kasus III	1.74	1.72	-0.01	0.70%
Kasus IV	1.80	1.78	-0.01	0.73%
Kasus V	1.82	1.81	-0.01	0.44%
Kasus VI	1.81	1.81	0.00	0.13%
Kasus VII	1.79	1.79	0.00	0.12%
Kasus VIII	1.75	1.76	0.01	0.31%
Kasus IX	1.70	1.71	0.01	0.45%
Kasus X	1.65	1.66	0.01	0.50%

Singkatan: FEA, analisis elemen hingga; WL-ε-TSVM, mesin vektor pendukung kembar Lagrange-ε berbobot.


#### 4.4 CONTOH NUMERIK STRUKTUR GRID SHELL

##### Informasi Struktural

Bagian ini menyajikan grid dengan bentuk batas melingkar untuk menampilkan penerapan proses prediksi bentuk yang disarankan, seperti yang ditampilkan pada Gambar 4.10. Tiga elemen diberi label  $M_1$ ,  $M_2$  dan  $M_3$  untuk penyelidikan, seperti yang ditunjukkan pada Gambar 4.11. ID simpul juga menunjukkan titik persimpangan dan ujung anggota. Grid bidang melingkar dipertimbangkan dengan diameter 12 m dan jarak antar grid 2 m. Panjang  $M_1$ ,  $M_2$  dan  $M_3$  adalah 12 m, 11,314 m, dan 8,944 m. Sebuah dataset yang mencakup enam faktor input ( $f_{1x}$ ,  $f_{1z}$ ,  $m_{1y}$ ,  $f_{2x}$ ,  $f_{2z}$ , dan  $m_{2y}$ ) dan faktor output (deformasi dan momen lentur) disiapkan untuk pelatihan dan pengujian algoritma. Mengubah nilai faktor input menghasilkan elemen ramping dan struktur gridshell yang dikenai berbagai kasus beban. Dalam observasi ini, 200 sampel dipertimbangkan dan dikenai berbagai kasus beban, termasuk 160 analisis elemen ramping sebagai set pelatihan dan 40 elemen struktur gridshell sebagai set pengujian untuk model WL- $\epsilon$ -TSVM.



**Gambar 4.10** Sistem struktur gridshell elastis.



**Gambar 4.11** Tata letak bidang grid dua lapis.

Sepuluh kasus dari set pengujian yang dikenai kasus beban berbeda disajikan sebagai Kasus I, Kasus II, ..., Kasus X untuk deskripsi rinci dalam bab ini. Kumpulan data yang disiapkan digunakan untuk memperkirakan deformasi dan momen lentur elemen gridshell. Perlu dicatat bahwa set pelatihan disiapkan dengan menganalisis elemen diskrit, sedangkan set pengujian disediakan dengan menganalisis struktur gridshell. Kisi datar yang dipelajari diharapkan terangkat di titik tengah, dan observasi ini mempertimbangkan berat sendiri elemen, mengabaikan berat elemen tambahan seperti konektor.

### **Model Elemen Hingga**

FEA adalah metode populer untuk analisis struktural gridshell. Dalam hal ini, penggabungan DOF digunakan untuk titik-titik yang digabungkan untuk mensimulasikan bagian struktural konektor perancah putar yang diterapkan untuk menggabungkan elemen dalam program ABAQUS melalui modul interaksi. DOF translasi dan rotasi di luar bidang digabungkan untuk sepasang simpul yang digabungkan. Oleh karena itu, simpul sambungan elemen sepanjang arah  $x$  dan  $y$  dikategorikan menjadi dua kelompok dan konektor didefinisikan antara kedua kelompok ini melalui modul interaksi.

Berat sendiri struktur dijelaskan dengan mempertimbangkan percepatan gravitasi 9,8 N/kg melalui modul beban. Material GFRP disimulasikan dengan  $D = 1850 \text{ kg/m}^3$  dan  $E = 26 \text{ GPa}$  menggunakan alat pengelola material dalam modul properti. Komponen balok B32 digunakan untuk mensimulasikan elemen, memungkinkan gaya aksial, geser, dan momen lentur dihitung secara tepat.

Tabung melingkar disimulasikan dengan diameter luar 50 mm dan ketebalan dinding 4 mm menggunakan alat pengelola penampang pada modul properti. Panjang elemen balok dibatasi hingga 200 mm oleh modul mesh dan tab mesh. Untuk memodelkan dampak tumpuan yang dihasilkan oleh kabel, perpindahan nodal diimplementasikan ke simpul tengah melalui modul beban. Gambar 4.12 menunjukkan FEA dari beberapa kasus, termasuk cangkang grid dua lapis dan elemen diskrit.

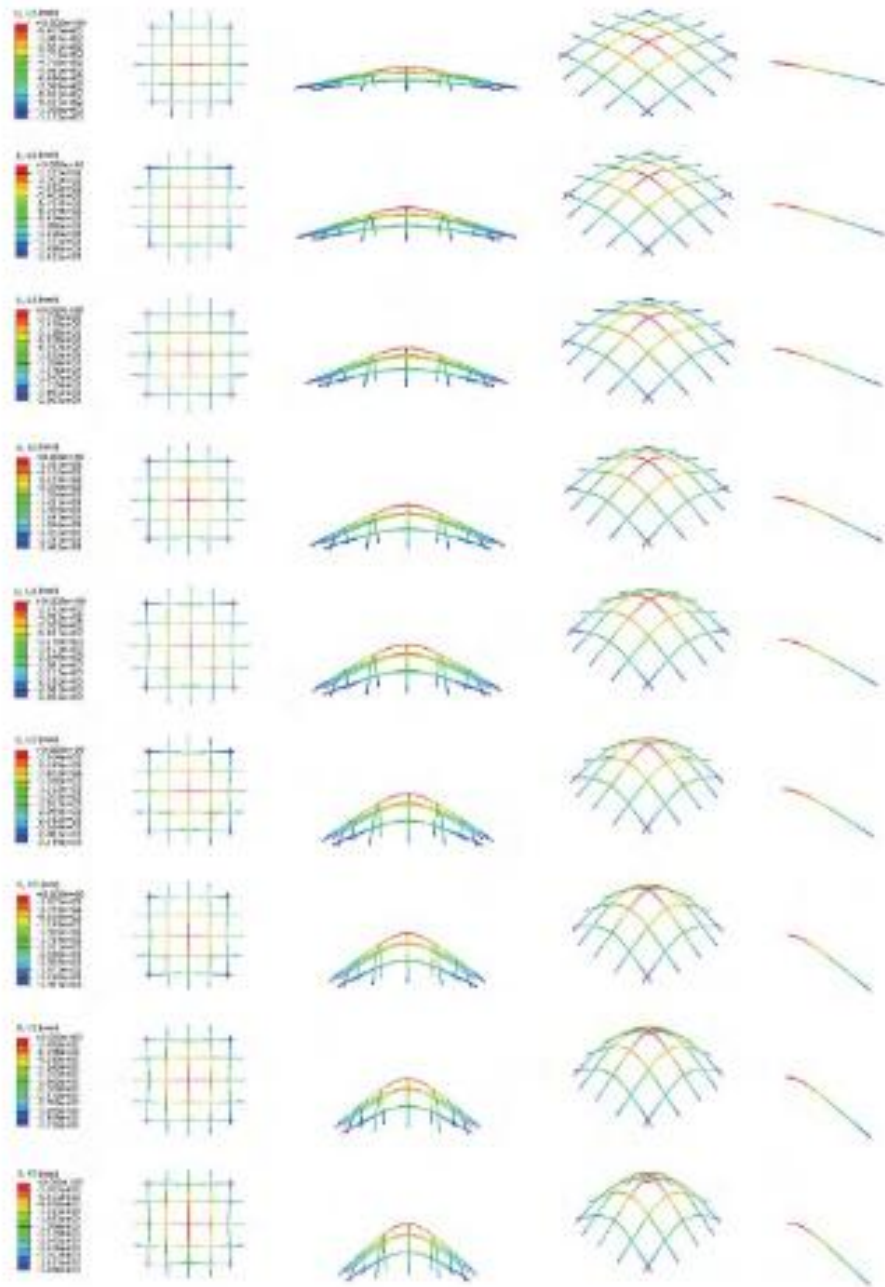
### **Penyetelan Parameter WL- $\epsilon$ -TSVM**

Untuk membangun model prediktif guna memperkirakan deformasi dan momen lentur elemen berdasarkan beban yang diterapkan, teknik WL- $\epsilon$ -TSVM dilakukan. Algoritma WL- $\epsilon$ -TSVM menawarkan kinerja generalisasi yang efisien dan kemampuan prediksi yang kuat jika hyperparameter dipilih dengan tepat. Dataset yang diperoleh digunakan untuk melatih model dalam program MATLAB, termasuk beban sebagai input dan deformasi serta momen lentur sebagai output. Validasi silang sepuluh kali lipat (CV) diimplementasikan untuk melatih algoritma. Dengan demikian, sepuluh putaran pelatihan dan validasi dilakukan menggunakan berbagai partisi, dan kinerja model ML ditunjukkan oleh rata-rata hasil di platform MATLAB.

Pendekatan TOPSIS digunakan di Excel untuk menghitung nilai respons berdasarkan nilai *root mean square error* (RMSE),  $R$ , dan waktu eksekusi. Respons TOPSIS diperoleh dengan menghitung matriks normalisasi, matriks normalisasi berbobot, nilai ideal terbaik dan ideal terburuk, jarak Euclidean dari nilai ideal terbaik dan ideal terburuk, dan skor kinerja. Metodologi Taguchi diimplementasikan dalam platform Minitab untuk menemukan variabel optimal dari enam parameter yang didefinisikan. Untuk setiap parameter, dikembangkan tiga level. Tabel 4.4 menunjukkan rentang dan level parameter WL- $\epsilon$ -TSVM. Dua puluh tujuh array ortogonal dibuat dengan pendekatan Taguchi. RMSE,  $R$ , dan waktu eksekusi didefinisikan sebagai respons array Taguchi. Tabel 4.5, 4.6, dan 4.7 menyajikan array ortogonal dan respons yang diperoleh dengan metode TOPSIS untuk output pertama, kedua, dan ketiga, masing-masing. Rasio Taguchi untuk algoritma ML yang terkait dengan tiga output digambarkan pada Gambar 4.13.

Oleh karena itu, parameter optimum dari algoritma WL- $\epsilon$ -TSVM dihitung sebagai  $C_1 = C_2 = 0.1, C_3 = C_4 = 1, C_5 = C_6 = 0.1, C_7 = C_8 = C_9 = C_{10} = 1, P = 6$  untuk  $F_3(z)$ , dan  $C_1 = C_2 = 0.1, C_3 = C_4 = C_5 = C_6 = 1, C_7 = C_8 = 0.01, C_9 = C_{10} = 1, P = 6$  untuk  $F_3(x)$ , dan  $C_1 = C_2 = 0.01, C_3 = C_4 = 1, C_5 = C_6 = 0.1, C_7 = C_8 = C_9 = C_{10} = 0.01, P = 6$  untuk  $F_3(y)$ .





**Gambar 4.12** Analisis cangkang kisi dan elemen diskrit.

**Tabel 4.4** Rentang dan Tingkat Parameter WL- $\epsilon$ -TSVM

Parameter	Rentang	Rendah (1)	Sedang (2)	Tinggi (3)
$C_1 = C_2$	0.01–1.0	0.01	0.1	1.0
$C_3 = C_4$	0.01–1.0	0.01	0.1	1.0
$C_5 = C_6$	0.01–1.0	0.01	0.1	1.0
$C_7 = C_8$	0.01–1.0	0.01	0.1	1.0
$C_9 = C_{10}$	0.01–1.0	0.01	0.1	1.0
<b>P</b>	2.0–6.0	2.0	4.0	6.0

**Tabel 4.5** Proses Kalibrasi WL- $\epsilon$ -TSVM untuk  $F_3(z)$

Urutan Percobaan	Parameter Algoritma						$F_3(z)$			
	1	2	3	4	5	6	RMSE	R	Waktu	Respons
1	1	1	1	1	1	1	140.8875	0.99193	25.01	0.00025
2	1	1	1	1	2	2	138.0729	0.99219	23.61	0.53227
3	1	1	1	1	3	3	135.4611	0.99251	23.72	0.64674
4	1	2	2	2	1	1	136.0945	0.99270	23.80	0.59382
5	1	2	2	2	2	2	133.7404	0.99282	23.64	0.76753
6	1	2	2	2	3	3	132.2007	0.99292	23.83	0.80599
7	1	3	3	3	1	1	131.8854	0.99323	23.64	0.88134
8	1	3	3	3	2	2	130.7547	0.99308	23.93	0.81027
9	1	3	3	3	3	3	131.0649	0.99298	23.81	0.84949
10	2	1	2	3	1	2	138.0729	0.99219	23.45	0.55846
11	2	1	2	3	2	3	135.4611	0.99251	23.85	0.61871
12	2	1	2	3	3	1	140.8875	0.99193	23.44	0.46688
13	2	2	3	1	1	2	133.7404	0.99282	23.88	0.71159
14	2	2	3	1	2	3	132.2007	0.99292	23.78	0.82226
15	2	2	3	1	3	1	136.0945	0.99270	23.83	0.58715
16	2	3	1	2	1	2	130.7547	0.99308	23.93	0.81027
17	2	3	1	2	2	3	131.0649	0.99298	23.76	0.86825
18	2	3	1	2	3	1	131.8854	0.99323	23.89	0.79815
19	3	1	3	2	1	3	135.4611	0.99251	23.77	0.63652
20	3	1	3	2	2	1	140.8875	0.99193	24.02	0.34447
21	3	1	3	2	3	2	138.0729	0.99219	23.90	0.46966
22	3	2	1	3	1	3	132.2007	0.99292	23.95	0.76594
23	3	2	1	3	2	1	136.0945	0.99270	23.44	0.65390
24	3	2	1	3	3	2	133.7404	0.99282	23.67	0.76183
25	3	3	2	1	1	3	131.0649	0.99298	23.83	0.84207
26	3	3	2	1	2	1	131.8854	0.99323	23.46	0.91712
27	3	3	2	1	3	2	130.7547	0.99308	23.77	0.86846

**Tabel 4.6** Proses Kalibrasi WL- $\epsilon$ -TSVM untuk  $F_3(x)$

Urutan Percobaan	Parameter Algoritma						$F_3(x)$			
	1	2	3	4	5	6	RMSE	R	Waktu	Respons
1	1	1	1	1	1	1	106.4798	0.98792	22.60	0.40667
2	1	1	1	1	2	2	104.2777	0.98834	23.01	0.38791
3	1	1	1	1	3	3	102.8288	0.98865	22.24	0.75121
4	1	2	2	2	1	1	103.4762	0.98883	23.24	0.37884
5	1	2	2	2	2	2	101.9409	0.98896	23.13	0.53397
6	1	2	2	2	3	3	101.1370	0.98902	22.96	0.64084

Urutan Percobaan	Parameter Algoritma						$F_3(x)$			
	1	2	3	4	5	6	RMSE	R	Waktu	Respons
7	1	3	3	3	1	1	100.8303	0.98944	23.05	0.62145
8	1	3	3	3	2	2	100.5487	0.98909	22.73	0.75591
9	1	3	3	3	3	3	100.7738	0.98894	22.93	0.66751
10	2	1	2	3	1	2	104.2777	0.98834	22.51	0.56552
11	2	1	2	3	2	3	102.8288	0.98865	23.03	0.50317
12	2	1	2	3	3	1	106.4798	0.98792	22.23	0.49795
13	2	2	3	1	1	2	101.9409	0.98896	23.06	0.55807
14	2	2	3	1	2	3	101.1370	0.98902	22.30	0.92037
15	2	2	3	1	3	1	103.4762	0.98883	22.76	0.55019
16	2	3	1	2	1	2	100.5487	0.98909	22.64	0.79571
17	2	3	1	2	2	3	100.7738	0.98894	22.76	0.73676
18	2	3	1	2	3	1	100.8303	0.98944	22.94	0.66163
19	3	1	3	2	1	3	102.8288	0.98865	22.23	0.75228
20	3	1	3	2	2	1	106.4798	0.98792	22.74	0.36109
21	3	1	3	2	3	2	104.2777	0.98834	22.97	0.40333
22	3	2	1	3	1	3	101.1370	0.98902	23.54	0.47468
23	3	2	1	3	2	1	103.4762	0.98883	23.10	0.42415
24	3	2	1	3	3	2	101.9409	0.98896	23.07	0.55453
25	3	3	2	1	1	3	100.7738	0.98894	22.83	0.70728
26	3	3	2	1	2	1	100.8303	0.98944	22.93	0.66547
27	3	3	2	1	3	2	100.5487	0.98909	22.85	0.70610

### Hasil Analisis

Plot regresi deformasi sepanjang arah  $z$  dan  $x$ , serta momen lentur, digambarkan pada Gambar 4.14. Nilai  $R$  terendah dan tertinggi dari sampel pengujian diperoleh oleh deformasi sepanjang arah  $x$  (0.98894) dan deformasi sepanjang arah  $z$  (0.99298), masing-masing. Gambar 4.15 menunjukkan perbandingan bentuk aktual dan prediksi elemen gridshell selama proses pengangkatan dan pemasangan yang diperoleh berdasarkan hasil analisis balok ramping, yang memverifikasi keakuratan metode yang disajikan.


**Tabel 4.7** Proses Kalibrasi WL- $\epsilon$ -TSVM untuk  $F_3(y)$

Urutan Percobaan	Parameter Algoritma						$F_3(y)$			
	1	2	3	4	5	6	RMSE	R	Waktu	Respons
1	1	1	1	1	1	1	0.1759	0.98894	22.54	0.37516
2	1	1	1	1	2	2	0.1660	0.99074	22.83	0.66208
3	1	1	1	1	3	3	0.1644	0.99114	22.95	0.70151
4	1	2	2	2	1	1	0.1673	0.99023	22.90	0.58785
5	1	2	2	2	2	2	0.1629	0.99130	22.36	0.88798


Urutan Percobaan	Parameter Algoritma						$F_3(y)$			
	1	2	3	4	5	6	RMSE	R	Waktu	Respons
6	1	2	2	2	3	3	0.1616	0.99167	22.75	0.84786
7	1	3	3	3	1	1	0.1608	0.99132	23.20	0.72309
8	1	3	3	3	2	2	0.1611	0.99173	23.33	0.68596
9	1	3	3	3	3	3	0.1609	0.99188	22.61	0.90603
10	2	1	2	3	1	2	0.1660	0.99074	22.73	0.62884
11	2	1	2	3	2	3	0.1644	0.99114	23.25	0.62455
12	2	1	2	3	3	1	0.1759	0.98894	22.93	0.28727
13	2	2	3	1	1	2	0.1629	0.99130	22.57	0.85910
14	2	2	3	1	2	3	0.1616	0.99167	22.98	0.77435
15	2	2	3	1	3	1	0.1673	0.99023	22.96	0.57481
16	2	3	1	2	1	2	0.1611	0.99173	23.49	0.64894
17	2	3	1	2	2	3	0.1609	0.99188	23.15	0.73534
18	2	3	1	2	3	1	0.1608	0.99132	23.37	0.68063
19	3	1	3	2	1	3	0.1644	0.99114	22.87	0.72212
20	3	1	3	2	2	1	0.1759	0.98894	23.30	0.18097
21	3	1	3	2	3	2	0.1660	0.99074	23.81	0.46007
22	3	2	1	3	1	3	0.1616	0.99167	22.73	0.85453
23	3	2	1	3	2	1	0.1673	0.99023	22.51	0.65797
24	3	2	1	3	3	2	0.1629	0.99130	23.03	0.72979
25	3	3	2	1	1	3	0.1609	0.99188	22.76	0.85408
26	3	3	2	1	2	1	0.1608	0.99132	22.88	0.81579
27	3	3	2	1	3	2	0.1611	0.99173	22.93	0.86860


Deformasi vertikal  $M_1$ ,  $M_2$  dan  $M_3$  digambarkan pada Gambar 4.16; kedua hasil yang dianalisis oleh FEA dan metode yang disajikan diusulkan. Perbedaan yang kecil dapat dilihat antara bentuk yang diperoleh oleh FEA dan algoritma ML untuk setiap anggota. Deformasi yang dihasilkan dari metode yang disajikan cukup mirip dengan hasil FEA. Tabel 4.8 menyajikan koordinat  $z$  dan  $x$  dari titik persimpangan, serta kesalahan dan kesalahan relatif. Deformasi yang dihasilkan dari metode yang disajikan cukup mirip dengan hasil FEA. Tabel 4.8 menyajikan koordinat  $z$  dan  $x$  dari titik-titik persimpangan, serta kesalahan dan kesalahan relatif.

Kesalahan relatif yang paling signifikan terjadi pada node  $D_2$  untuk  $F_1(x)$ , sebesar 5,03%, dan kesalahan besaran yang sesuai dihitung sebesar -5,73 mm. Pada node  $D_4$  untuk  $F_3(z)$ , kesalahan relatif minimum adalah 1,51%, dan kesalahan besaran terkait sama dengan -39,66 mm. Karena node  $D_2$  terletak di dekat pusat grid, perpindahan vertikalnya relatif kecil dibandingkan dengan  $D_3$  dan  $D_4$ . Tabel 4.9 menyajikan perbandingan momen lentur pada  $D_4$  untuk gridshell di bawah proses pengangkatan dengan nilai kesalahan relatif tertinggi dan terendah masing-masing sebesar 4,60% (Kasus IV) dan 0,70% (Kasus VI). Kesimpulannya, metode yang diusulkan tampaknya sesuai untuk prediksi bentuk struktur cangkang jaring elastis GFRP di bawah prosedur pemasangan dengan pengangkatan.

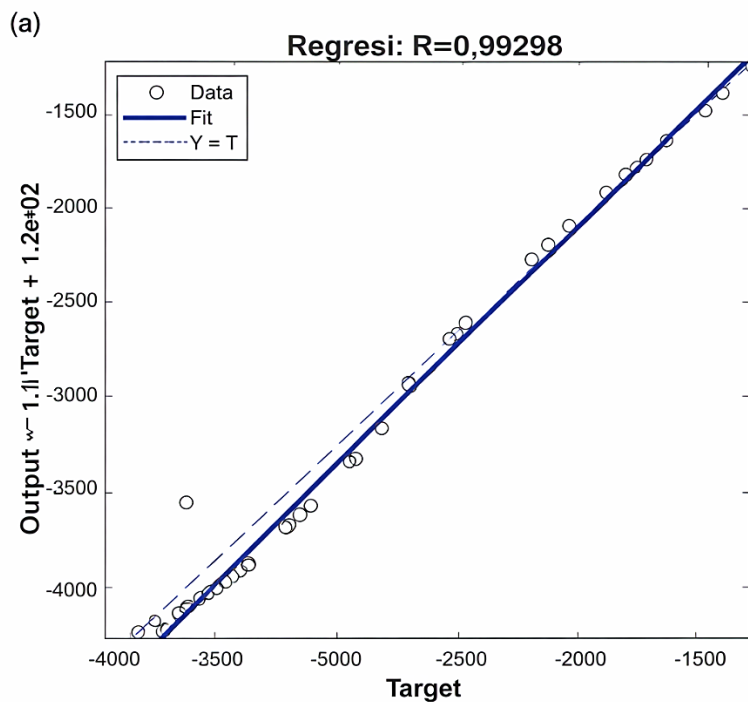


**Gambar 4.13** Rasio Taguchi untuk WL- $\epsilon$ -TSVM dari: (a)  $f_3(z)$ , (b)  $f_3(x)$ , dan (c)  $f_3(y)$ .  
 . (Bersambung)








Gambar 4.13 (Lanjutan)




Gambar 4.14 Plot regresi dari: (a)  $f_3(z)$ , (b)  $f_3(x)$ , dan (c)  $f_3(y)$ . (Bersambung)



Gambar 4.14 (Lanjutan)



**Gambar 4.15** Perbandingan bentuk aktual dan prediksi elemen gridshell selama proses pengangkatan dan pemasangan.



**Gambar 4.16** Deformasi elemen struktural.

**Tabel 4.8** Perbandingan koordinat z untuk Sambungan Grid

$Z_{end}$ (mm)			$X_{end}$ (mm)		
$D_2$	$D_3$	$D_4$	$D_2$	$D_3$	$D_4$

	Z <sub>end</sub> (mm)			X <sub>end</sub> (mm)		
<b>FEA</b>	-608.45	-1600.22	-2624.96	-113.93	-377.55	-660.04
<b>WL-ε-TSVM</b>	-590.16	-1568.59	-2585.30	-108.20	-366.60	-646.86
<b>Galat</b>	-18.29	-31.63	-39.66	-5.73	-10.95	-13.18
<b>Galat relatif</b>	3.01%	1.98%	1.51%	5.03%	2.90%	1.99%

Singkatan: FEA, analisis elemen hingga; WL-ε-TSVM, mesin vektor pendukung kembar Lagrange-ε berbobot.

**Tabel 4.9** Perbandingan Momen Lentur di  $D_1$  untuk Struktur Cangkang Kisi

Kasus	Momen Lentur (N.m)			
	FEA	WL-ε-TSVM	Galat	Galat Relatif
Kasus I	-2.4790	-2.4495	0.0295	1.19%
Kasus II	-2.8686	-2.9252	-0.0566	1.97%
Kasus III	-3.2245	-3.3432	-0.1187	3.68%
Kasus IV	-3.5494	-3.7126	-0.1632	4.60%
Kasus V	-3.8463	-3.9313	-0.0850	2.21%
Kasus VI	-4.1179	-4.0893	0.0286	0.70%
Kasus VII	-4.3668	-4.2398	0.1270	2.91%
Kasus VIII	-4.5951	-4.4253	0.1699	3.70%
Kasus IX	-4.8052	-4.6572	0.1481	3.08%
Kasus X	-4.9988	-4.9030	0.0958	1.92%

#### 4.5 PREDIKSI BENTUK GRID SHELL GFRP DENGAN WL-ε-TSVM

Struktur gridshell elastis GFRP ringan dan berkelanjutan karena penggunaan material yang minimal. Bentuk akhir gridshell elastis GFRP dicapai melalui deformasi elastis dari kisi datar selama proses pengangkatan dan pemasangan. Karena non-linearitas geometris yang signifikan, memprediksi bentuk gridshell merupakan proses yang kompleks. Bab ini bertujuan untuk menyajikan teknik prediksi berdasarkan pendekatan ML untuk memperkirakan fitur struktural gridshell selama prosedur konstruksi pengangkatan. Kebaruan pendekatan ini terletak pada kenyataan bahwa, alih-alih melakukan analisis yang memakan waktu untuk seluruh struktur, fitur elemen diskrit digunakan untuk menyiapkan kumpulan data. Kepraktisan metode yang diusulkan dalam menganalisis gridshell divalidasi oleh dua contoh numerik: gridshell elastis berbentuk kubah barel dan gridshell simetris biaxial di bawah konstruksi pengangkatan. Algoritma WL-ε-TSVM digunakan untuk menganalisis contoh numerik, dengan mempertimbangkan deformasi geometris yang signifikan.

Kombinasi metode CV sepuluh kali lipat, TOPSIS, dan Taguchi diterapkan untuk menyetel variabel model ML. Nilai R terendah dan tertinggi untuk sampel pengujian diperoleh untuk deformasi sepanjang arah  $x$  (0.98894) dan arah  $z$  (0.99298), masing-masing. Proses prediksi bentuk juga disajikan berdasarkan metode yang diusulkan untuk memperkirakan deformasi dan momen lentur cangkang grid elastis selama proses pengangkatan dan pemasangan. Pendekatan yang diusulkan selanjutnya divalidasi oleh FEA untuk memastikan kepraktisan dan akurasi. Hasilnya, metode yang disarankan terbukti tepat untuk

menganalisis cangkang grid elastis, dan prosedur prediksi bentuk yang disajikan efektif untuk memperkirakan deformasi dan momen lentur cangkang grid selama proses konstruksi pengangkatan.

## **BAB 5**

### **PENENTUAN BENTUK GRIDSHELL GFRP PENGANGKATAN**

#### **5.1 TINJAUAN METODE PENCARIAN BENTUK GRIDSHELL**

Proses penentuan bentuk merupakan tahap kritis dalam desain struktur spasial bentang lebar. Berbagai metode penentuan bentuk berdasarkan analisis elemen hingga (FEA), relaksasi dinamis, dan metode kepadatan gaya telah disajikan dalam literatur. Teknik penentuan bentuk umumnya digunakan untuk mengoptimalkan topologi kisi dan bentuk struktural struktur rangka spasial, dengan mempertimbangkan distribusi gaya internal dan penggunaan baja.

Analisis penentuan bentuk diperlukan untuk struktur prategang seperti struktur membran dan jaring kabel untuk menentukan bentuk akhir, serta untuk menemukan panjang kabel dan pola pemotongan membran. Tang dan Li menyajikan teknik kepadatan gaya ekuivalen untuk analisis sistem kabel-membran, meningkatkan konvergensi dan efisiensi komputasi. Pargana dkk. mengusulkan pendekatan FEA inovatif untuk membran dan kabel, berdasarkan asumsi yang lebih dekat dengan realitas fisik untuk struktur membran yang ditegangkan, memungkinkan analisis yang lebih andal dan akurat. Pendekatan pencarian bentuk yang inovatif dan hibrida untuk struktur spesifik dapat dikembangkan dalam studi masa depan dengan memahami fitur-fitur metode analitis yang ada dan interrelasinya.

Dalam beberapa tahun terakhir, berbagai metode pencarian bentuk berdasarkan prinsip numerik atau matematis telah diusulkan. Peloux dkk. mengembangkan program menggunakan pendekatan kompas untuk berhasil menghasilkan grid datar dari permukaan referensi. Bouhaya dkk. memperkenalkan teknik pencarian bentuk berdasarkan program FE. Dalam metode mereka, mesh datar yang lebar ditempatkan pada kerangka dan dideformasi menjadi bentuk akhir di bawah pengaruh gravitasi dalam program.

Pemangkasan kelebihan panjang tabung bengkok pada kerangka memungkinkan batas kerangka datar untuk diidentifikasi. Li dkk. mengusulkan pendekatan komputasi untuk mendapatkan kondisi dukungan dan pola grid, dengan mempertimbangkan energi regangan minimal. Yusuke dan Makoto memperkenalkan teknik desain bentuk berdasarkan teori elastis diskrit, menunjukkan penerapan metode tersebut dengan membandingkan permukaan yang dirancang dengan permukaan yang dihasilkan menggunakan FEA. Tugas penting dalam mendesain cangkang kisi elastis adalah menentukan kisi datar yang sesuai yang akan menghasilkan bentuk struktur yang diinginkan. Dalam sistem struktur seperti ini, hal ini disebut sebagai proses pencarian bentuk.

Dalam beberapa tahun terakhir, integrasi pemodelan informasi bangunan (BIM) dengan teknik optimasi telah membuka peluang baru dalam proses pencarian bentuk. BIM menyediakan lingkungan kolaboratif yang memfasilitasi pertukaran informasi yang efisien antara berbagai pemangku kepentingan, memungkinkan pendekatan yang lebih efisien untuk desain dan analisis. Melalui penerapan BIM, proses pencarian bentuk struktural dapat dioptimalkan, meningkatkan ketelitian dan koordinasi desain struktur spasial. Selain itu, ketika

dikombinasikan dengan teknik optimasi, BIM memungkinkan pendekatan holistik yang mempertimbangkan seluruh siklus hidup struktur, dari desain awal hingga konstruksi dan pemeliharaan.

Analisis elemen hingga (FEA) biasanya diterapkan untuk analisis struktural. Namun, FEA merupakan prosedur yang kompleks dan memakan waktu. Oleh karena itu, diperlukan teknik pengganti dengan prosedur komputasi yang cepat dan mudah. Dalam beberapa tahun terakhir, pendekatan berbasis data telah dikembangkan sebagai pengganti proses simulasi yang memakan waktu. Metode berbasis data memecahkan masalah rekayasa struktural melalui biaya komputasi yang rendah dan prosedur yang akurat.

Selama dekade terakhir, pendekatan kecerdasan buatan (AI) dan pembelajaran mesin (ML) semakin banyak diimplementasikan untuk memodelkan masalah rekayasa struktur dunia nyata. Hal ini karena kemampuan luar biasa mereka untuk menangkap hubungan matematika nonlinier atau rumit antara data masukan dan keluaran. Huang dan Burton menggunakan metode ML untuk mendeteksi mode kegagalan bidang pada rangka beton bertulang (RC) dengan pengisi dan mengamati bahwa algoritma *support vector machine* (SVM) dan *adaptive boosting* memiliki akurasi yang wajar. Selain itu, pendekatan ini mampu diterapkan selama prosedur pembentukan bentuk.

## **5.2 METODE ANALISIS UNTUK GRIDSHELL**

### **Prinsip Proses Pembentukan Bentuk**

Prosedur pembentukan bentuk dalam observasi ini didasarkan pada prosedur pengangkatan dan pemasangan grid yang berubah bentuk ke batas struktur. Proses teknis pembentukan bentuk menghasilkan kisi datar dua lapis yang tepat. Prediksi bentuk atau ukuran batas kisi datar awal dimungkinkan dengan pendekatan ML interpretabel berdasarkan beberapa parameter struktural seperti lebar, tinggi, ukuran tabung polimer yang diperkuat serat kaca (GFRP), dan lokasi titik pengangkatan. Proses pencarian bentuk yang disajikan menghasilkan bentuk batas struktur cangkang kisi dengan karakteristik deformasi optimal. Prinsip-prinsip berikut harus dipertimbangkan selama prosedur pencarian bentuk:

1. Deformasi elemen harus dipertimbangkan selama prosedur pencarian bentuk.
2. Kondisi pengangkatan mengontrol morfologi bentuk akhir. Misalnya, titik pengangkatan mengontrol ketinggian pelana dan punuk struktur, dan penilaian deformasi elemen karakteristik memverifikasi bentuk akhir struktur.
3. Ketinggian ujung elemen pada kisi elastis yang diangkat ke udara harus berada pada level horizontal yang sama untuk pemasangan penyangga; namun, penyimpangan kecil diperbolehkan.
4. Simulasi konstruksi dapat dilakukan berdasarkan lokasi pengangkatan yang tepat yang diperoleh selama proses pencarian bentuk.

### **Tahap-Tahap Proses Konstruksi**

Empat tahap proses konstruksi cangkang jaring elastis GFRP adalah sebagai berikut:

- *Tahap I:* Tabung GFRP lurus ditempatkan secara ortogonal di tanah dan elemen-elemen dirakit dengan konektor untuk membuat jaring datar.



- *Tahap II:* Derek mengangkat jaring datar setelah kabel gantung dipasang ke sambungan elemen yang sesuai. Hasilnya, bentuk perkiraan cangkang jaring diperoleh dengan mendefleksikan kisi datar di bawah gravitasi.
- *Tahap III:* Cangkang jaring dibawa ke puncak posisi yang diinginkan, dan ujung elemen dihubungkan ke penyangga yang terletak di pondasi. Setelah itu, kabel gantung dilepas.
- *Tahap IV:* Terakhir, elemen lapisan atas dipasang secara diagonal. Bentuk akhir struktur diperoleh ketika perakitan konektor antara elemen lapisan tengah dan lapisan atas selesai.

### **Prosedur Analisis**

Proses pencarian bentuk adalah sebagai berikut:

1. Tentukan nilai parameter desain dan hasilkan beberapa bentuk cangkang kisi dengan mengubah nilai-nilai tersebut. Dalam studi ini, bentuk kacang sebagai bentuk batas dengan jarak yang sama antara elemen paralel dipertimbangkan.
2. Pertimbangkan deviasi standar dan deviasi maksimum sebagai fungsi tujuan. Ketika kisi digantung, semua ujung anggota harus dekat dengan elevasi yang sama untuk memudahkan pemasangan penyangga. Dalam hal ini, dua kebutuhan diharapkan terpenuhi. Awalnya, deviasi standar koordinat  $z$  pada ujung elemen harus kurang dari nilai yang diizinkan yaitu 0.01 m, yang diukur sebagai:

$$F_1(x) = S_z = \sqrt{\frac{\sum_{i=1}^n (z_i - z_0)^2}{n}} \quad (5.1)$$

di mana  $n$  menunjukkan jumlah total ujung anggota, dan  $z_i$  mengacu pada koordinat  $z$  dari ujung anggota. Selanjutnya, deviasi maksimum yang harus kurang dari 0.03 m, dapat didefinisikan sebagai:

$$F_2(x) = D_z = \max(|z_i - z_0|) \quad (5.2)$$

3. Manfaatkan FEA untuk simulasi kinerja mekanik struktur yang dikenai gravitasi dan peroleh fungsi tujuan untuk setiap sampel.
4. Siapkan kumpulan data yang terdiri dari variabel desain dan fungsi tujuan.
5. Latih model ML untuk memprediksi fungsi tujuan.
6. Gunakan metode interpretasi untuk memperoleh nilai optimal variabel desain.
7. Tentukan tata letak akhir kisi datar dengan memperoleh panjang optimal elemen transversal karakteristik dan simulasikan bentuk akhir cangkang kisi optimal dengan variabel desain yang diperoleh.
8. Simulasikan prosedur pengangkatan dengan platform FEA dan lakukan analisis struktural.



### 5.3 CONTOH NUMERIK

#### Deskripsi


Dalam studi ini digunakan cangkang kisi elastis GFRP dengan dua titik pengangkatan, seperti yang diilustrasikan pada Gambar 5.1. Struktur tersebut dikenai gravitasi selama simulasi pembentukan dan konstruksi. Bidang kaku dibuat dan di-mesh, dan kisi datar awalnya ditempatkan di tanah untuk memodelkan dampak penopang. Elemen kontak ditentukan sebagai tanpa gesekan pada bidang horizontal dan keras pada arah vertikal, memungkinkan perhitungan langsung gaya pendukung vertikal. Kontak keras vertikal dirancang hanya untuk kompresi, yang berarti bahwa jika simpul grid berpindah ke atas, komponen kontak akan dinonaktifkan. Grid datar diangkat ke ketinggian yang diinginkan selama analisis dengan menerapkan perpindahan yang ditentukan ke simpul.

Selama prosedur pengangkatan, grid akan melengkung secara substansial karena gravitasi. Studi ini mempertimbangkan nonlinieritas geometris dan linearitas material untuk mensimulasikan deformasi struktural yang signifikan secara akurat. Karena bentuk gridshell telah ditetapkan oleh proses pengangkatan, penyangga engsel dipasang pada ujung elemen untuk menahan gridshell pada Tahap III dan IV, mencegah translasi ujung anggota dalam arah  $x$ ,  $y$ , dan  $z$  tetapi memungkinkan rotasi di luar bidang. Koordinat simpul grid yang terdeformasi digunakan untuk memasang elemen lapisan atas pada Tahap IV. Karena kelengkungan anggota ini lebih rendah dibandingkan dengan elemen lapisan tengah dan bawah, dampak lentur elemen ini tidak dipertimbangkan. Setiap segmen elemen antara sambungan dibagi menjadi empat komponen, menghasilkan panjang elemen balok 0.25 m dalam program ABAQUS melalui modul mesh. Jarak antar elemen grid sama dengan 1 m.

Konektor perancah putar digunakan untuk menghubungkan persimpangan anggota melalui modul interaksi. Oleh karena itu, translasi relatif dan rotasi di luar bidang antara node dicegah, sedangkan rotasi di dalam bidang diizinkan. Elemen balok B32 digunakan untuk mensimulasikan anggota. Sifat mekanik GFRP didefinisikan sebagai  $E = 26$  GPa,  $D = 1850$  kg/m<sup>3</sup>, dan  $V = 0.28$  oleh alat pengelola material dalam modul properti. Berbagai penampang didefinisikan oleh alat pengelola penampang dalam modul properti. Sebuah dataset disiapkan dengan menghasilkan beberapa geometri struktural dengan mempertimbangkan lebar ( $P_1, P_2, P_3$ ), jari-jari ( $R$ ), ketebalan ( $T$ ), lokasi titik pengangkatan ( $L_1, L_2$ ), dan tinggi ( $H_1, H_2$ ) sebagai variabel desain, seperti yang diilustrasikan pada Gambar 5.1. Atribut statistik dari sampel disajikan pada Tabel 5.1.

Selanjutnya, serangkaian bentuk struktural yang terdiri dari 300 sampel dengan rasio pelatihan 70% disiapkan untuk proses pelatihan dan pengujian model ML. Sebuah studi perbandingan dilakukan dengan Python pada delapan model ML, termasuk SVM, *K-nearest neighbor* (KNN), *decision tree* (DT), *random forest* (RF), AdaBoost, XGBoost, CatBoost, dan LightGBM, untuk memprediksi deformasi gridshell. Hyperparameter ditemukan menggunakan kombinasi pendekatan pencarian grid dan validasi silang k-fold (CV). Rentang potensial dari setiap parameter pertama kali ditetapkan sebagai grid berdasarkan literatur. Model kemudian dilatih berulang kali menggunakan semua kemungkinan kombinasi grid parameter, dan kinerjanya dievaluasi menggunakan CV k-fold. Akibatnya, nilai-nilai dengan kinerja CV k-fold

terbaik dipilih sebagai hiperparameter model. Tabel 5.2 menunjukkan nilai optimal hiperparameter untuk setiap model ML.



**Gambar 5.1** Variabel desain dari gridshell GFRP double-hump.

**Tabel 5.1** Atribut Statistik dari Dataset

Atribut	Satuan	Minimum	Maksimum	Rata-rata
P <sub>1</sub>	m	10	12	11
P <sub>2</sub>	m	8	10	9
P <sub>3</sub>	m	10	12	11
R	m	0.026	0.03	0.028
T	m	0.004	0.006	0.005
L <sub>1</sub>	m	10	12	11
L <sub>2</sub>	m	28	30	29
H <sub>1</sub>	m	4	6	5
H <sub>2</sub>	m	4	6	5

**Tabel 5.2** Parameter Hiperoptimal Model ML

Model	Keluaran	Konfigurasi Optimal
<b>SVM</b>	f <sub>1</sub> (x)	Kernel = rbf, C = 0.1, degree = 0.1, epsilon = 0.01
	f <sub>2</sub> (x)	Kernel = rbf, C = 0.1, degree = 0.1, epsilon = 0.01
<b>KNN</b>	f <sub>1</sub> (x)	leaf_size = 30, n_neighbors = 2, p = 1
	f <sub>2</sub> (x)	leaf_size = 30, n_neighbors = 2, p = 1
<b>DT</b>	f <sub>1</sub> (x)	max_depth = 8, min_samples_leaf = 1, min_samples_split = 3, random_state = 3
	f <sub>2</sub> (x)	max_depth = 8, min_samples_leaf = 1, min_samples_split = 2, random_state = 0
<b>RF</b>	f <sub>1</sub> (x)	max_depth = 9, max_features = 5, n_estimators = 200
	f <sub>2</sub> (x)	max_depth = 9, max_features = 5, n_estimators = 100
<b>AdaBoost</b>	f <sub>1</sub> (x)	learning_rate = 1, n_estimators = 100, random_state = 0
	f <sub>2</sub> (x)	learning_rate = 0.1, n_estimators = 1000, random_state = 1

Model	Keluaran	Konfigurasi Optimal
<b>XGBoost</b>	$f_1(x)$	colsample_bytree = 1, learning_rate = 0.5, max_depth = 2, n_estimators = 1000
	$f_2(x)$	colsample_bytree = 0.9, learning_rate = 0.1, max_depth = 3, n_estimators = 1000
<b>CatBoost</b>	$f_1(x)$	Depth = 3, iterations = 2000, learning_rate = 0.1
	$f_2(x)$	Depth = 3, iterations = 2000, learning_rate = 0.1
<b>LightGBM</b>	$f_1(x)$	Colsample_bytree = 0.6, learning_rate = 0.5, max_depth = 4, n_estimators = 1000
	$f_2(x)$	Colsample_bytree = 0.5, learning_rate = 0.5, max_depth = 3, n_estimators = 1000

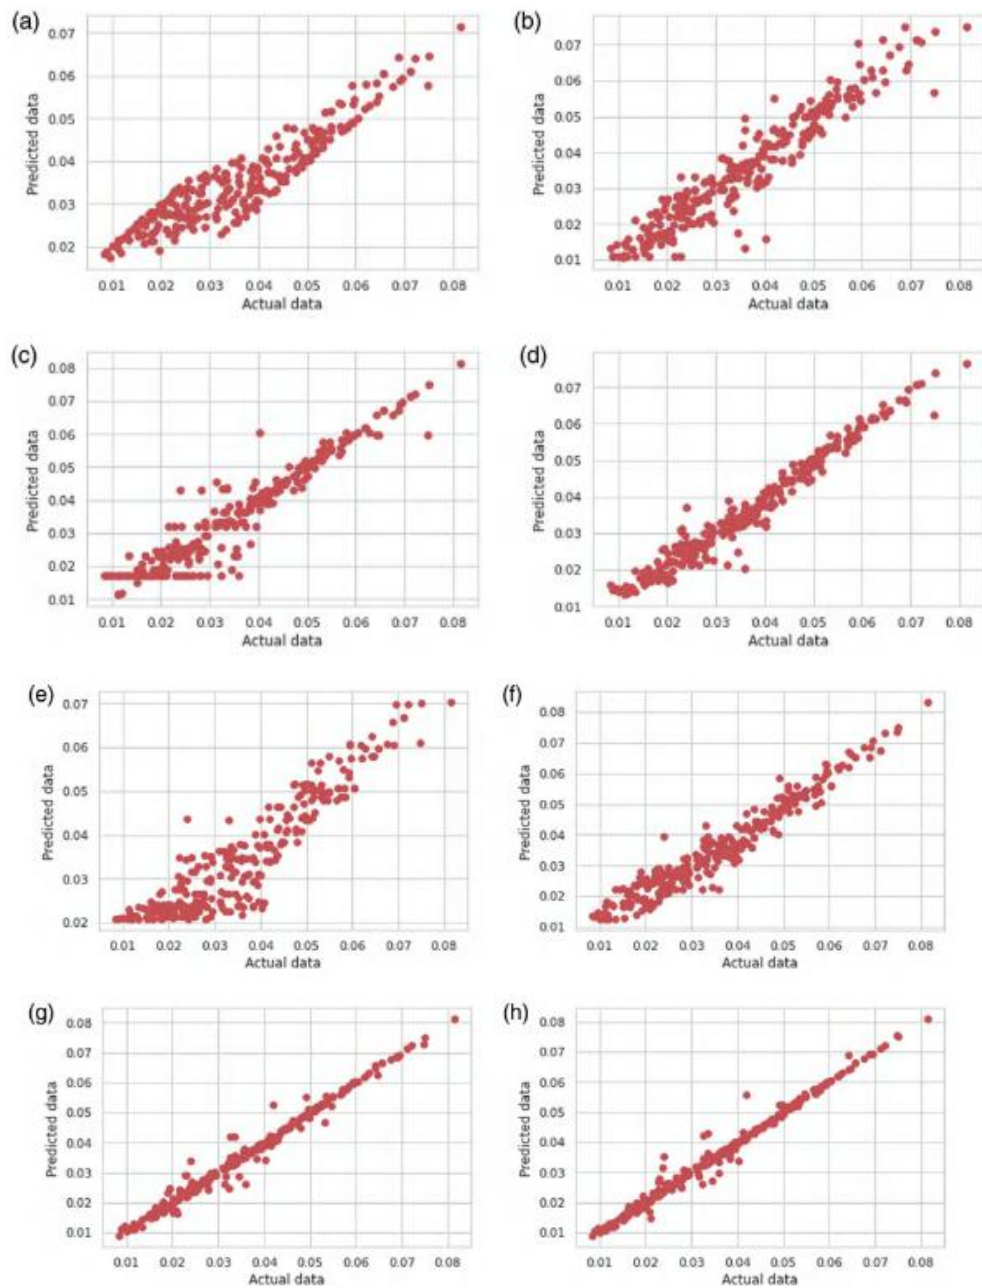
### Model Regresi

Plot regresi dari berbagai model ML ditunjukkan pada Gambar 5.2 dan 5.3, yang mengkonfirmasi efisiensi tinggi dari model LightGBM.  $R^2$  dan kesalahan kuadrat rata-rata (RMSE) dari  $F_1(x)$  ditunjukkan pada Tabel 5.3. Model LightGBM menunjukkan RMSE terendah (0,003) dan  $R^2$  tertinggi (0.946) untuk sampel uji. Tabel 5.4 menyajikan RMSE dan  $R^2$  dari sampel pelatihan dan pengujian untuk menilai kinerja delapan algoritma ML. Hasilnya menunjukkan bahwa metode LightGBM adalah model terbaik dengan RMSE terendah (0.008) dan  $R^2$  tertinggi (0.851). Akibatnya, pendekatan LightGBM dipilih dalam bab ini untuk menyelidiki pengaruh berbagai algoritma ML yang dapat diinterpretasikan.

### Metode yang dapat Diinterpretasikan

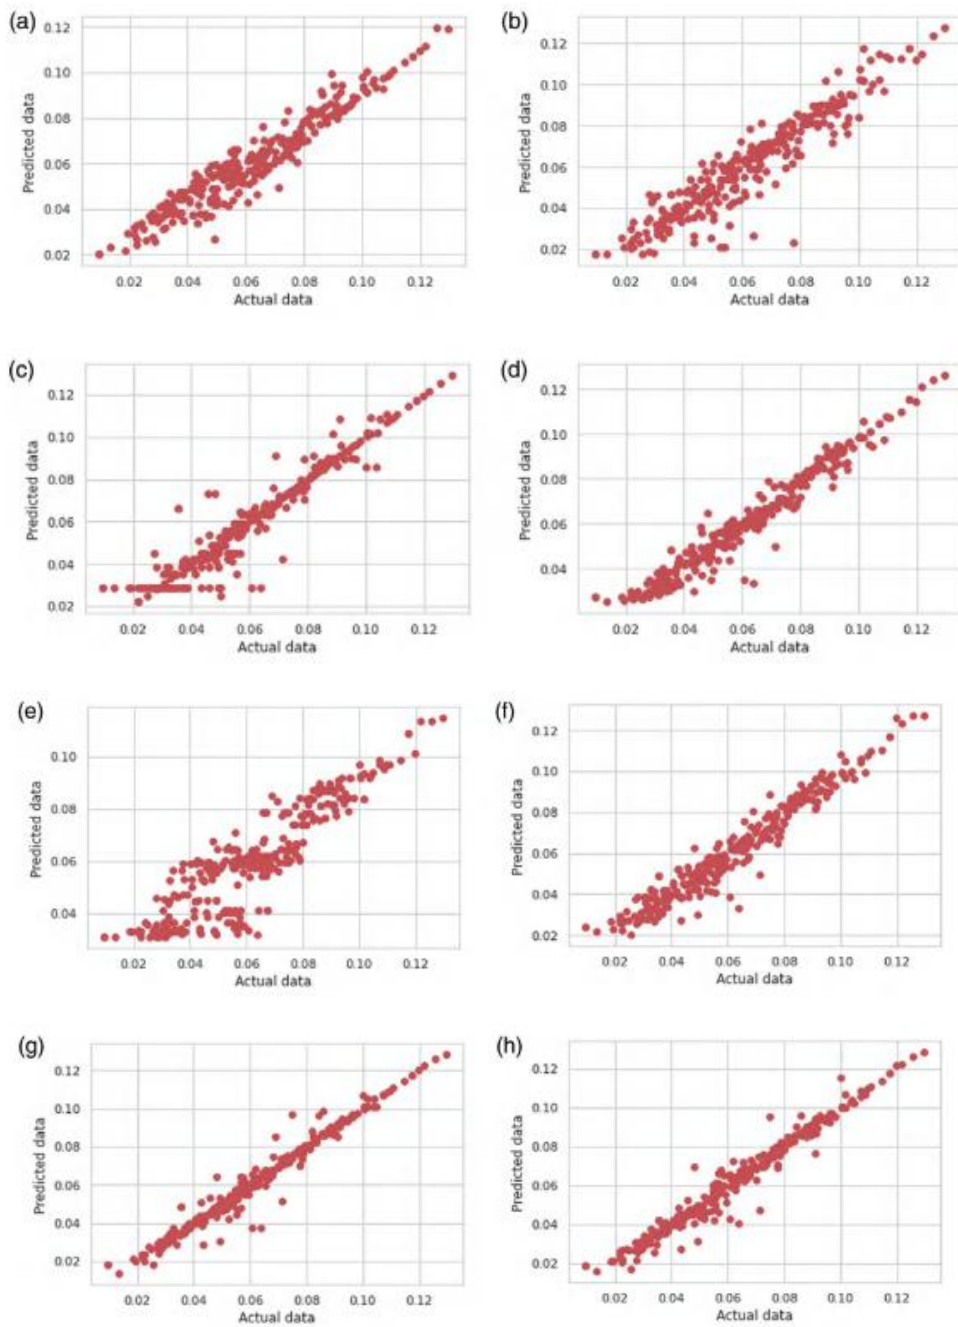
LightGBM memiliki kemampuan pentingnya fitur untuk interpretasi seperti kebanyakan model berbasis pohon. Berdasarkan pengaruh setiap faktor terhadap setiap pohon dalam model, Gambar 5.4 menunjukkan signifikansi variabel dalam pengembangan model LightGBM untuk  $F_1(x)$ . Fitur input  $L_1$  adalah faktor terpenting, diikuti oleh fitur  $L_2$ . Parameter yang paling tidak penting adalah  $T$ , diikuti oleh parameter  $R$ .

Gambar 5.4b menunjukkan faktor penting yang dihasilkan dari model LightGBM untuk  $F_2(x)$ , dengan  $L_2$ ,  $L_1$ , dan  $P_3$  sebagai fitur yang paling signifikan. Namun,  $F_2(x)$  sedikit dipengaruhi oleh parameter input  $T$ ,  $R$ , dan  $P_2$ . Namun, tidak mungkin untuk menentukan apakah parameter input memiliki efek negatif atau positif pada plot kepentingan relatif.





**Gambar 5.2** Plot regresi  $f_1(x)$ : (a) SVM, (b) KNN, (c) DT, (d) RF, (e) AdaBoost, (f) XGBoost, (g) CatBoost, dan (h) LightGBM.

Plot SHAP adalah ilustrasi visual dari pelatihan model LightGBM yang diperoleh dengan pustaka SHAP di Python. Plot ringkasan SHAP digambarkan pada Gambar 5.5, dengan setiap titik mewakili nilai Shapley untuk parameter tersebut.



**Gambar 5.3** Plot regresi  $f_2(x)$ : (a) SVM, (b) KNN, (c) DT, (d) RF, (e) AdaBoost, (f) XGBoost, (g) CatBoost, dan (h) LightGBM.



**Gambar 5.4** Faktor kepentingan LightGBM untuk: (a)  $f_1(x)$  dan (b)  $f_2(x)$ .

**Tabel 5.3** Kinerja Model Regresi Berbasis ML untuk Prediksi  $F_1(x)$

Cangkang Kisi		
Metode Regresi	R <sup>2</sup> Rata-rata	RMSE Rata-rata
SVM	0,168	0,013
KNN	0,815	0,006
DT	0,731	0,007


Metode Regresi	R <sup>2</sup> Rata-rata	RMSE Rata-rata
RF	0,873	0,005
AdaBoost	0,727	0,007
XGBoost	0,873	0,005
CatBoost	0,944	0,003
LightGBM	<b>0,946</b>	<b>0,003</b>

**Tabel 5.4** Kinerja Model Regresi Berbasis ML untuk Prediksi  $F_2(x)$  pada Gridshell


Metode Regresi	R <sup>2</sup> Rata-rata	RMSE Rata-rata
SVM	0,185	0,020
KNN	0,760	0,011
DT	0,765	0,011
RF	0,834	0,009
AdaBoost	0,664	0,013
XGBoost	0,816	0,009
CatBoost	0,847	0,008
LightGBM	<b>0,851</b>	<b>0,008</b>

Gambar 5.5 menunjukkan bahwa setiap baris berisi jumlah sampel yang sama. Nilai Shapley dan parameter input masing-masing merupakan absis dan ordinat dari plot ini. Variabel-variabel tersebut diurutkan berdasarkan tingkat kepentingannya dari yang paling penting hingga yang paling tidak penting, dengan variabel yang paling penting terletak di bagian atas. Beberapa sampel dari suatu faktor dengan nilai SHAP yang identik tersebar di sepanjang sumbu horizontal untuk mewakili kejadian dengan nilai SHAP tertentu. Rentang nilai yang meningkatkan nilai SHAP dan dengan demikian estimasi terkait ditunjukkan oleh warna merah.

Warna merah menunjukkan efek positif, sedangkan warna biru menunjukkan efek negatif. Dampak positif mengacu pada peningkatan prediksi seiring dengan peningkatan faktor input. Peningkatan variabel  $L_2, P_2$  dan  $R$  menyebabkan penurunan nilai SHAP dan  $F_1(x)$  menurun. Sebaliknya, peningkatan  $L_1, P_1, P_3, H_1$ , dan  $T$  menyebabkan peningkatan nilai  $F_1(x)$ . Gambar 5.5b menggambarkan nilai SHAP secara keseluruhan.  $R$  memiliki efek negatif paling signifikan dalam memprediksi  $F_2(x)$ , sedangkan  $L_1$  memiliki dampak positif paling signifikan dalam memprediksi  $F_2(x)$ , seperti yang ditunjukkan pada Gambar 5.5b. Secara umum,  $L_2, R$ , dan  $P_2$  memprediksi  $F_2(x)$  secara negatif, sedangkan  $L_1, P_3, P_1$ , dan  $T$  memprediksi  $F_2(x)$  secara positif.

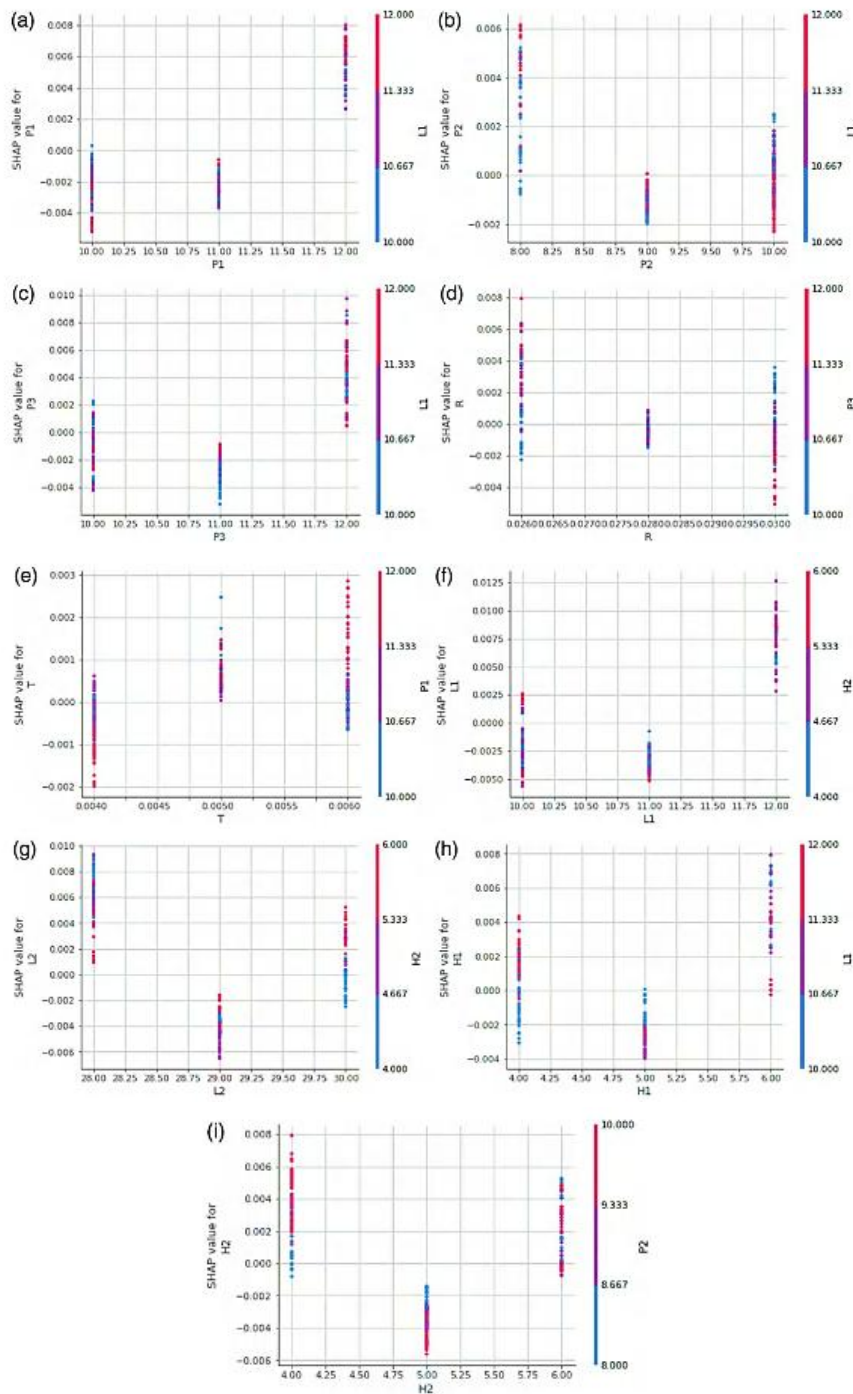


Gambar 5.5 Plot SHAP untuk nilai Shapley gridshell: (a)  $f_1(x)$  dan (b)  $f_2(x)$ .



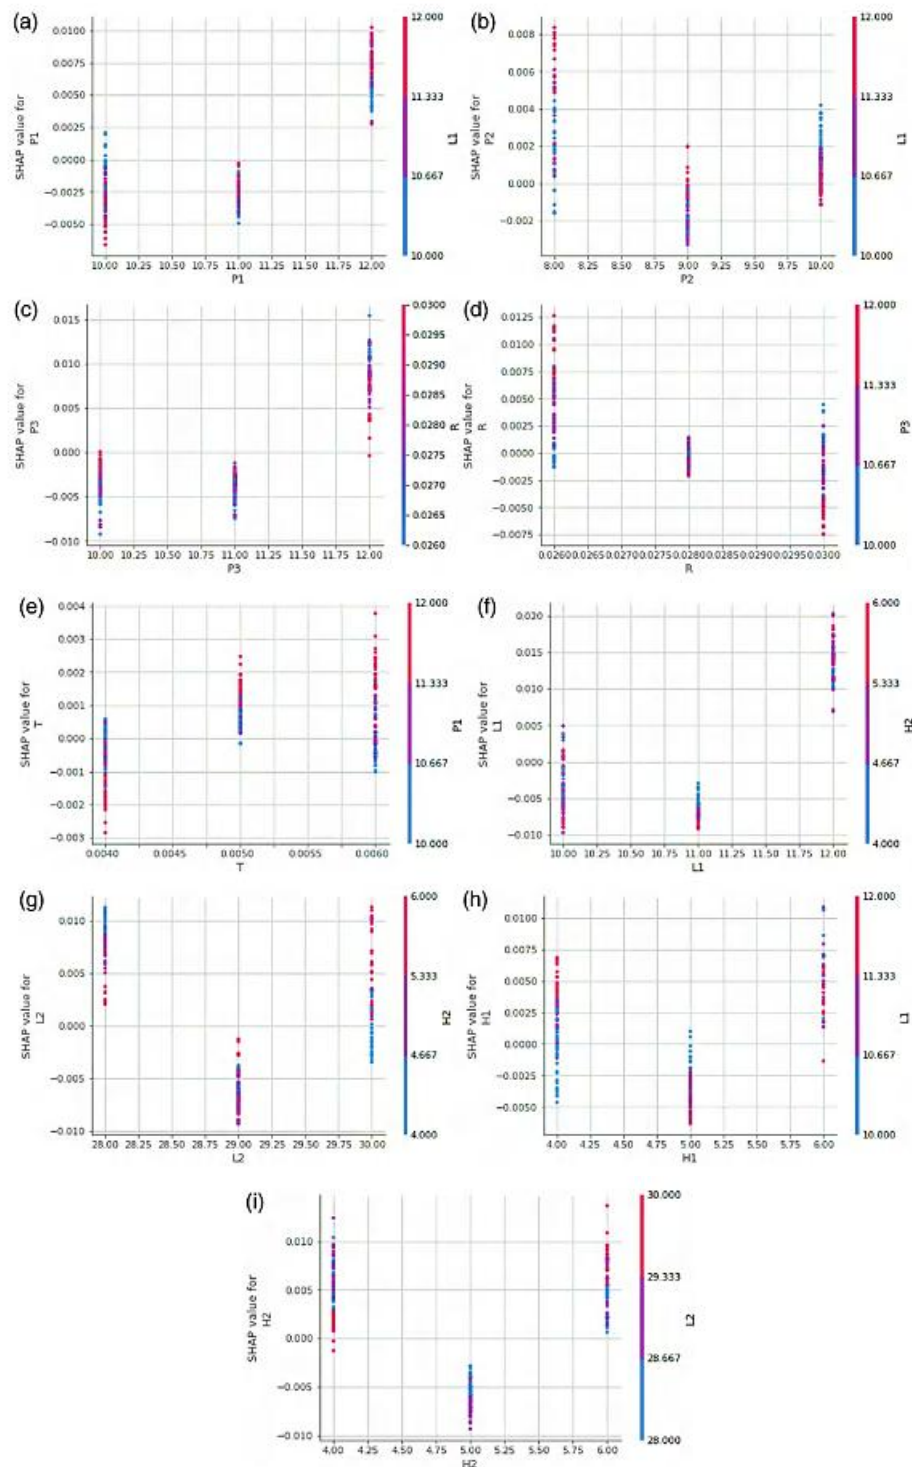
**Gambar 5.6** Plot SHAP untuk faktor kepentingan global gridshell: (a)  $f_1(x)$  dan (b)  $f_2(x)$ .

Nilai SHAP menawarkan modul yang kuat untuk menghitung dan menyajikan plot kepentingan fitur dengan `shap.summary_plot` di Python. Faktor signifikansi global diwakili pada Gambar 5.6 sebagai rata-rata absolut nilai SHAP per faktor. SHAP mendefinisikan bahwa variabel input  $L_1$  adalah faktor yang paling kritis, sebanding dengan kesimpulan dari variabel signifikansi LightGBM.



**Gambar 5.7** Plot ketergantungan parsial SHAP untuk  $f_1(x)$ : (a) P1-L1; (b) P2-L1; (c) P3-L1; (d) R-P3; (e) T-P1; (f) L1-H2; (g) L2-H2; (h) H1-L1; (i) H2-P2.

Dalam memprediksi  $F_2(x)$  dari struktur gridshell,  $L_1$  adalah fitur yang paling signifikan, diikuti oleh  $L_2$  dan  $P_1$ , seperti yang ditunjukkan pada Gambar 5.6a. Dalam memprediksi  $F_2(x)$  dari struktur gridshell,  $L_1$  adalah fitur penting, diikuti oleh  $L_2$  dan  $H_2$ , seperti yang ditunjukkan pada Gambar 5.6b.  $T$  adalah faktor yang paling tidak penting untuk kedua output.

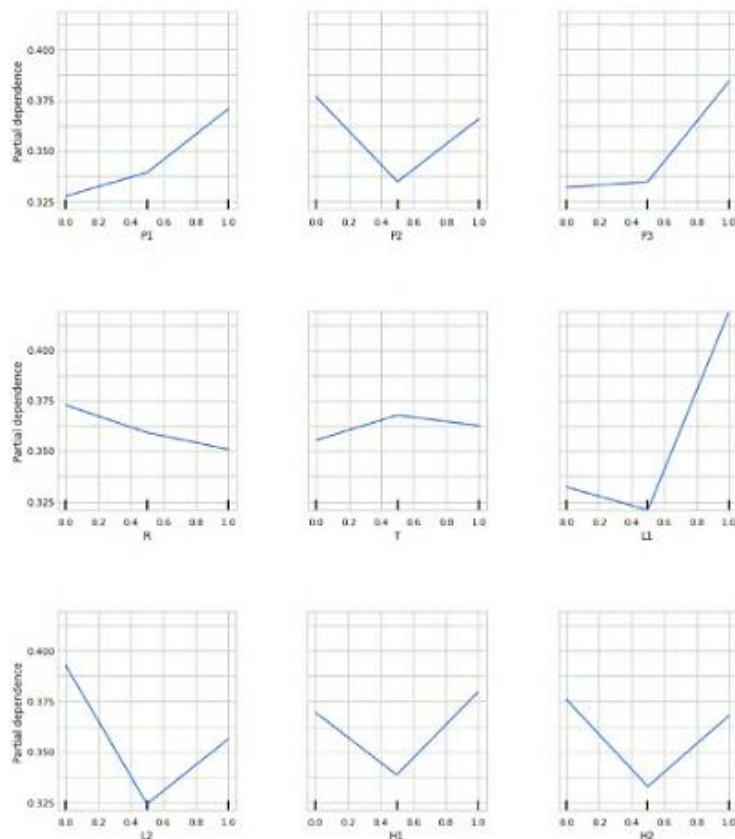


**Gambar 5.8** Plot ketergantungan parsial SHAP untuk  $f_2(x)$ : (a) P1-L1; (b) P2-L1; (c) P3-R; (d) R-P3; (e) T-P1; (f) L1-H2; (g) L2-H2; (h) H1-L1; (i) H2-L2.

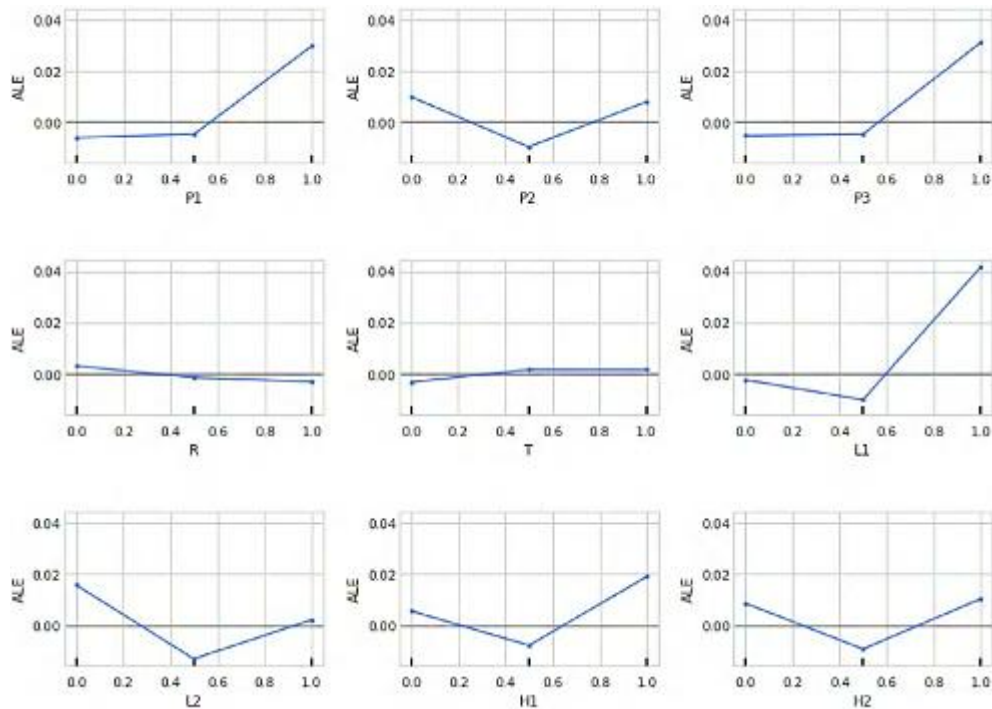
Fitur signifikansi global dalam LightGBM menentukan  $L_1$  sebagai fitur paling signifikan kedua, sedangkan SHAP mendeteksi  $L_2$  sebagai fitur paling penting kedua karena perbedaan utama dalam penilaian faktor kepentingan. SHAP menggunakan pentingnya fitur input dalam estimasi output, sedangkan LightGBM menerapkan pentingnya fitur input dalam konstruksi pohon keputusan. Namun, fitur-fitur teratas yang dipilih oleh SHAP dan LightGBM identik.

Gambar 5.7 dan 5.8 menggambarkan bahwa SHAP menyajikan grafik ketergantungan yang merupakan plot sebaran nilai SHAP dari suatu parameter dengan parameter lain. Warna mencerminkan dampak interaksi variabel lain dengan nilai sumbu horizontal. Plot ketergantungan parsial SHAP memberikan wawasan yang luas tentang hubungan parameter input. Dapat dilihat bahwa sebagian besar menunjukkan perilaku nonlinier. Pengaruh  $L_1$  terhadap  $P_1$  ditunjukkan pada Gambar 5.7a. Jelas bahwa untuk semua nilai  $P_1$  kecuali 12 m, nilai SHAP menurun seiring dengan peningkatan  $L_1$ .

Pengaruh positif  $P_1$  meningkat seiring dengan peningkatan  $T$ , berdasarkan Gambar 5.7e. Selain itu, dampak positif terutama dapat diamati pada kasus  $L_2$  dan  $H_2$ , seperti yang ditunjukkan pada Gambar 5.7g. Gambar 5.7i menunjukkan bahwa  $P_2$  secara negatif memengaruhi nilai SHAP untuk parameter input  $H_2$  untuk nilai lebih besar atau sama dengan 50%. Plot lainnya menunjukkan bahwa untuk variabel lain, nonlinieritas meningkat. Perlu dicatat bahwa plot ketergantungan parsial (PDP) dan plot efek lokal terakumulasi (ALE) tidak dapat digunakan untuk inferensi semacam itu.



**Gambar 5.9** PDP variabel input untuk  $f_1(x)$ .



**Gambar 5.10** ALE variabel input untuk  $f_1(x)$ .

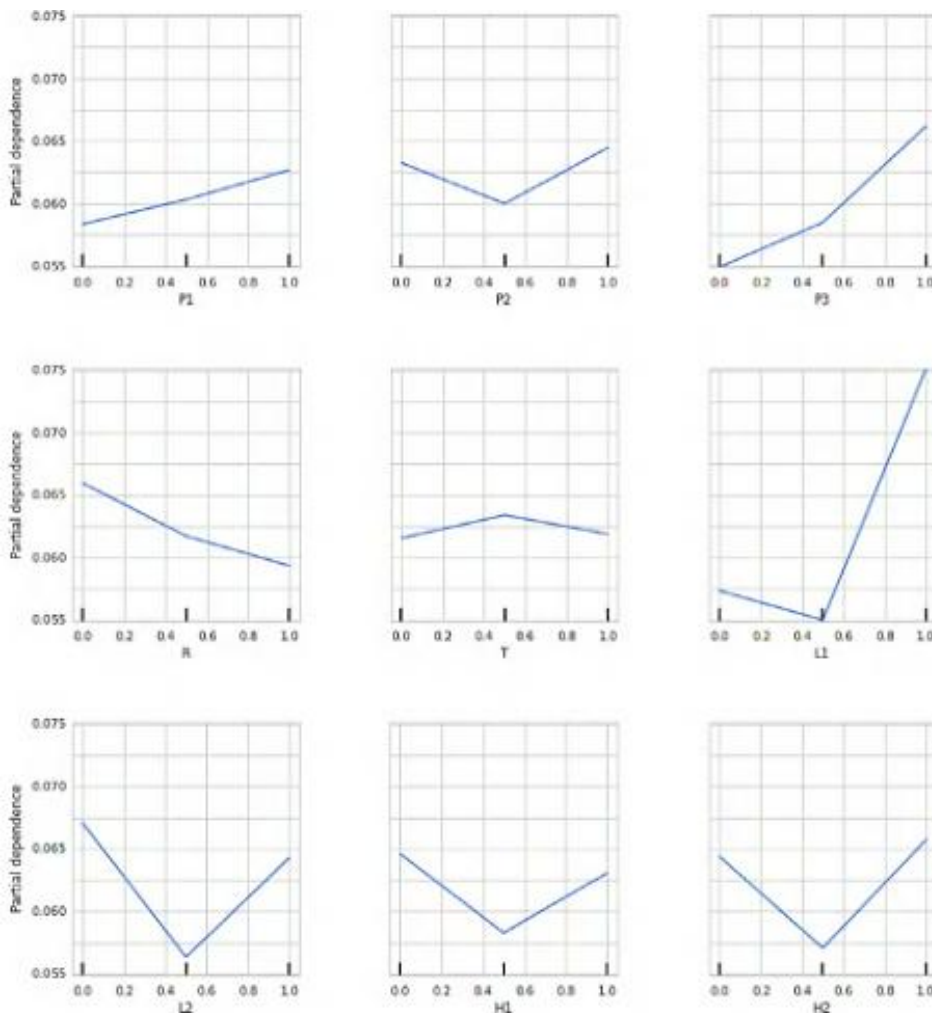
Gambar 5.8 mengilustrasikan bahwa korelasi antar fitur pada dasarnya bersifat non-linier. Gambar 5.8a menampilkan pengaruh nilai SHAP terhadap variabel  $L_1$  dan  $P_1$ . Terlihat jelas bahwa untuk  $P_1$  lebih besar atau sama dengan 11 m, nilai SHAP  $P_1$  meningkat seiring dengan peningkatan  $L_1$ . Namun, trennya berbalik untuk  $P_1$  kurang dari 11 m. Lebih lanjut, nilai SHAP  $T$  lebih tinggi untuk  $P_1$  yang lebih besar ketika  $T$  lebih besar atau sama dengan 0,005 m, sedangkan trennya berbalik dan menghasilkan nilai SHAP negatif dalam kasus  $T$  kurang dari 0.005 m, seperti yang ditunjukkan pada Gambar 5.8e. Plot lainnya menunjukkan bahwa variabel lain sering berinteraksi secara linier.

Plot PDP dan ALE adalah satu-satunya cara untuk menentukan apakah parameter input memiliki efek negatif atau positif pada plot kepentingan relatif, seperti yang digambarkan pada Gambar 5.9, 5.10, 5.11, dan 5.12. Modul `sklearn.inspection` dan pustaka `Alibi` digunakan dalam Python untuk menghasilkan plot PDP dan ALE dari model `LightGBM`. Setiap grafik mewakili variasi estimasi metode `LightGBM` dibandingkan dengan rata-rata estimasi ketika variabel input diubah. Selain itu, grafik tersebut menyajikan ambang batas perubahan parameter input yang menyebabkan prediksi model berubah. PDP bertujuan untuk menunjukkan hasil model rata-rata  $F_1(x)$  dalam hal nilai-nilai berbeda dari estimator di seluruh rentang parameter, sedangkan ALE menyajikan hasil rata-rata pada rentang parameter tertentu.

Hasil menunjukkan bahwa plot ALE dan PDP memiliki tren yang hampir identik. Variabel  $L_1$  merupakan fitur penting. Peningkatan  $P_1$  meningkatkan nilai  $F_1(x)$ , seperti yang ditunjukkan pada Gambar 5.9 dan Gambar 5.10. Selain itu, parameter terpenting kedua,  $L_2$ , berdampak negatif pada prediksi  $F_1(x)$  hingga mencapai 50%. Nilai  $F_1(x)$  menurun seiring meningkatnya  $R$ . Selain itu, nilai  $F_1(x)$  meningkat ketika  $P_2$ ,  $L_1$ ,  $L_2$ ,  $H_1$ , dan  $H_2$  melebihi nilai median.  $P_3$  tidak secara signifikan memengaruhi output hingga mencapai 50%. Variabel input

$T$  dan  $R$  memiliki dampak paling kecil pada  $F_1(x)$ , yang juga ditunjukkan pada Gambar 5.6. Terdapat hubungan linier antara  $R$  dan  $F_1(x)$ . Secara umum,  $P_1$  dan  $P_3$  memiliki efek positif, sedangkan  $R$  berdampak negatif pada  $F_1(x)$ .

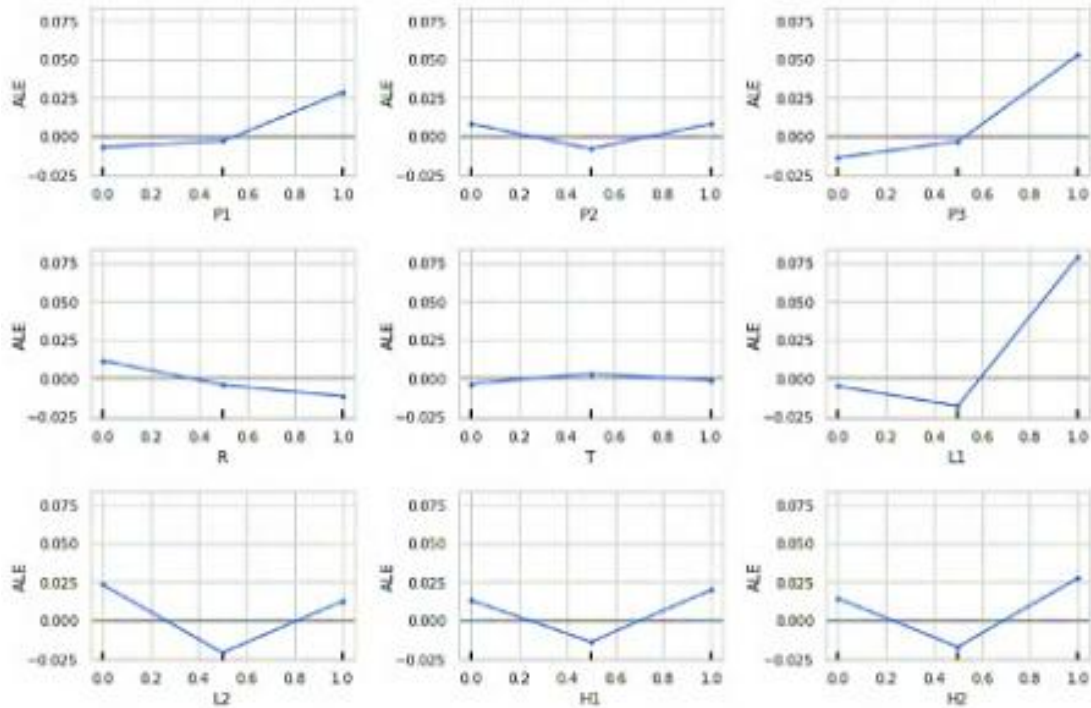
Gambar 5.11 dan 5.12 menunjukkan arah dampak faktor-faktor dan ambang batas di mana variasi estimasi dapat diselidiki dengan grafik PDP dan ALE, masing-masing. Bahkan untuk perilaku yang berkorelasi, plot ALE dan PDP menunjukkan kecenderungan yang sebanding. Fitur input, kecuali  $T$ , memiliki dampak signifikan pada  $F_2(x)$ . Hubungan antara  $F_2(x)$  dan  $P_1$  bersifat linier. Terdapat perubahan cepat pada nilai  $F_2(x)$  ketika  $L_1$  melebihi 0,5 kali nilai rata-rata.  $F_2(x)$  hampir identik untuk nilai  $T$  yang berbeda. Secara umum,  $P_1$  dan  $P_3$  memiliki efek positif, sedangkan  $R$  berdampak negatif pada  $F_2(x)$ . Meskipun Gambar 5.6 memberi peringkat fitur, dampak fitur hanya dapat ditentukan oleh plot ALE dan PDP. Namun, memberi peringkat fitur berdasarkan plot ALE atau PDP sangatlah menantang.




**Gambar 5.11** PDP variabel input untuk  $f_2(x)$ .

Hasil observasi menunjukkan bahwa satu metode interpretasi saja tidak cukup untuk menjelaskan sepenuhnya perilaku metode ML, dan diperlukan kumpulan pendekatan interpretasi untuk menyelidiki perilaku ML secara komprehensif. Sebagai hasil dari pendekatan


interpretasi, gridshell dengan  $P_1 = 10, P_2 = 9, P_3 = 10, R = 0.03, T = 0.004, L_1 = 11, L_2 = 29, H_1 = 5$ , dan  $H_2 = 5$  menunjukkan nilai  $F_1(x)$  dan  $F_2(x)$  terendah, dan ditunjukkan pada Gambar 5.13 (Kasus 1). Selain itu, gridshell dengan  $P_1 = 12, P_2 = 8, P_3 = 12, R = 0.026, T = 0.005, L_1 = 12, L_2 = 28, H_1 = 6, H_2 = 4$  diperoleh dengan nilai  $F_1(x)$  dan  $F_2(x)$  maksimum (Kasus 2).



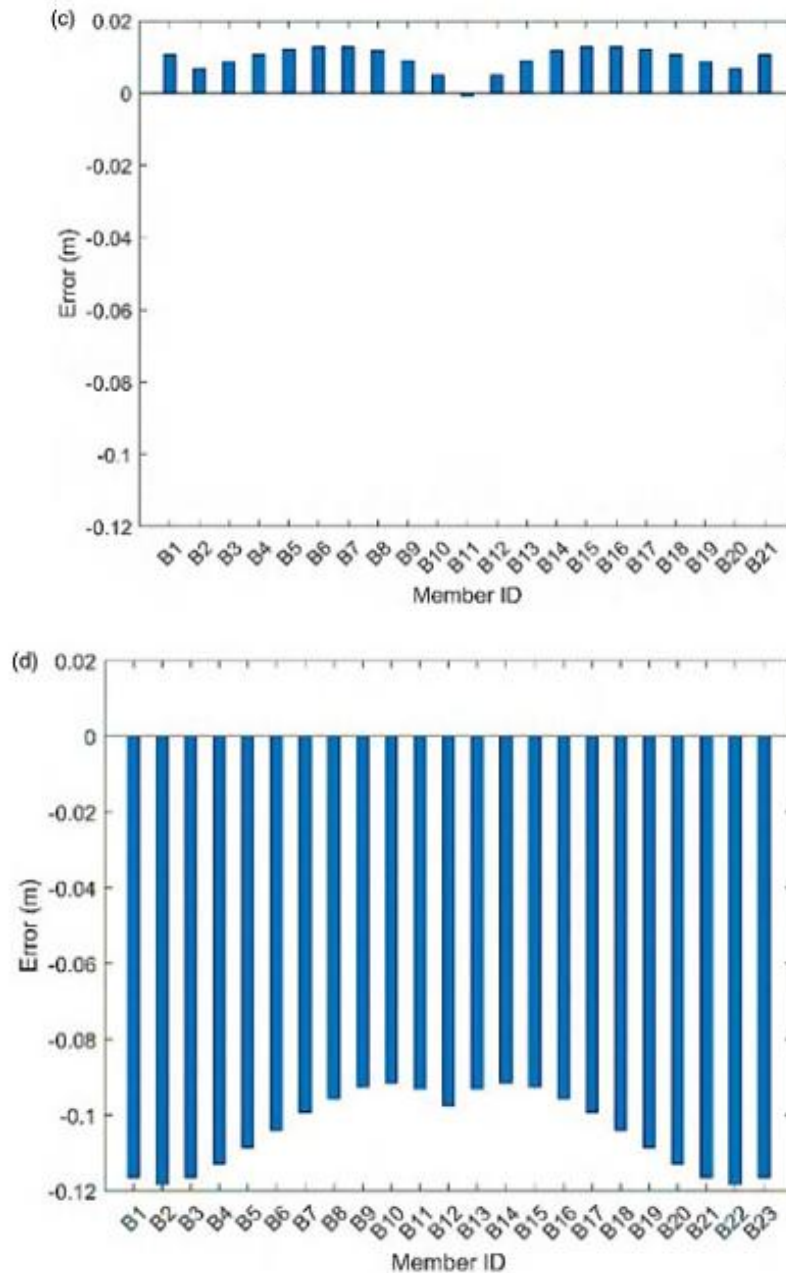
**Gambar 5.12** ALE variabel input untuk  $f_2(x)$ .



**Gambar 5.13** Kisi datar optimal dari struktur cangkang kisi.




**Gambar 5.14** Penyimpangan elevasi dari: (a) ujung anggota melintang kasus 1, (b) ujung anggota melintang kasus 2, (c) ujung anggota memanjang kasus 1, dan (d) ujung anggota memanjang kasus 2 (sisi punuk bawah). (Bersambung)



**Gambar 5.14** (Lanjutan)

### Penyimpangan Elevasi Ujung Elemen

Penyimpangan elevasi pada ujung elemen melintang dan memanjang Kasus 1 dan Kasus 2 juga ditunjukkan pada Gambar 5.14. Diamati bahwa penyimpangan elevasi Kasus 1 secara signifikan lebih rendah daripada Kasus 2. Penyimpangan pada semua ujung elemen Kasus 1 ditentukan dalam 0.015 m, yang hanya setengah dari toleransi untuk elemen memanjang (0.03 m). Akibatnya, kisi datar akhir yang diperoleh dengan proses ini dapat diandalkan karena kesalahan yang kecil.




**Gambar 5.15** Deformasi cangkang kisi: (a) tahap I, (b) tahap II, (c) tahap III, dan (d) tahap IV.

### Hasil Simulasi Konstruksi

Kisi datar akhir yang diperoleh selanjutnya diadopsi untuk teknik konstruksi ketika prosedur pencarian bentuk selesai. Gambar 5.15 menunjukkan deformasi struktur pada empat tahap, termasuk Tahap I, yang sesuai dengan kisi datar di lantai; Tahap II, yang sesuai dengan kisi dua lapis yang menggantung di udara; Tahap III, yang sesuai dengan cangkang kisi elastis yang terpasang pada lantai; Tahap IV, yang sesuai dengan struktur cangkang kisi akhir.

Bentuk struktur berubah dari kisi datar di lantai menjadi struktur akhir di atas fondasi selama keempat tahap ini. Gambar 5.16 menggambarkan distribusi tegangan struktur cangkang kisi yang maksimum di sepanjang sumbu titik pengangkatan. Dapat dilihat bahwa tegangan maksimum kurang dari 70 MPa yang jauh lebih rendah daripada kekuatan material tabung GFRP. Oleh karena itu, penerapan metode yang disajikan telah diverifikasi.



**Gambar 5.16** Distribusi tegangan struktur gridshell (MPa).

## 5.4 PENCARIAN BENTUK GRID SHELL GFRP PENGANGKATAN

Bab ini menyajikan metode baru untuk pencarian bentuk struktur gridshell berdasarkan pendekatan ML yang dapat diinterpretasikan. Studi perbandingan dilakukan pada beberapa algoritma ML, termasuk SVM, KNN, DT, RF, AdaBoost, XGBoost, CatBoost, dan LightGBM. Contoh numerik diberikan menggunakan gridshell double-hump standar. Parameter input yang dipertimbangkan dalam studi ini adalah tiga faktor lebar, radius dan ketebalan tabung GFRP, dua lokasi punuk, dan dua tinggi punuk. Selain itu, fungsi objektifnya adalah dua karakteristik deformasi. Hiperparameter terbaik untuk algoritma ML ditentukan menggunakan kombinasi pendekatan pencarian grid dan CV sepuluh kali lipat. Hasil studi perbandingan menunjukkan bahwa algoritma LightGBM mencapai akurasi prediksi tertinggi. Selanjutnya, kepentingan relatif dari berbagai fitur diidentifikasi untuk pendekatan ML yang

berkinerja terbaik. Terakhir, pendekatan ML yang dapat diinterpretasikan, termasuk SHAP, PDP, dan ALE, diterapkan untuk menjelaskan prediksi.

Metode yang dapat diinterpretasikan ini memberi peringkat fitur input dan menjelaskan tren dalam estimasi. SHAP digunakan untuk menggambarkan pentingnya setiap variabel terhadap deformasi, baik secara lokal maupun global. Nilai SHAP menunjukkan bahwa variabel yang paling signifikan adalah  $L_1$  untuk  $F_1(x)$  dan  $F_2(x)$ , dengan dampak positif pada hasil estimasi. Fitur-fitur paling signifikan yang ditunjukkan dalam plot kepentingan fitur dari metode LightGBM konsisten dengan yang diperoleh menggunakan metode SHAP. Sebagai hasil dari pendekatan interpretabilitas ini, struktur gridshell yang optimal diperoleh.

Deviasi di semua ujung elemen dari kasus optimal ditentukan berada dalam 0.015 m, yang hanya setengah dari toleransi untuk anggota longitudinal (0.03 m). Oleh karena itu, kisi datar akhir yang diperoleh melalui proses ini dapat diandalkan karena kesalahan minimal. Setelah prosedur pencarian bentuk, proses konstruksi disimulasikan secara numerik. Distribusi tegangan pada elemen struktur menunjukkan dampak terkonsentrasi pada titik pengangkatan yang dihasilkan oleh kabel penghubung, yang harus mendapat perhatian khusus selama proses konstruksi. Oleh karena itu, hasil observasi ini menyoroti peluang baru untuk investigasi pembentukan struktur gridshell dengan proses pemasangan pengangkatan, yang bermanfaat dalam fase desain dan analisis.



## **BAB 6**

### **PENILAIAN KINERJA STRUKTURAL GRIDSHELL ELASTIS GFRP**

#### **6.1 ANALISIS STRUKTURAL GRIDSHELL GFRP DENGAN ML**

Saat ini, permintaan akan struktur berkelanjutan telah meningkat. Memilih material dan sistem yang tepat sesuai dengan penilaian siklus hidup dan dampak lingkungan merupakan salah satu strategi untuk membangun struktur yang ramah lingkungan. Struktur gridshell adalah atap kisi ringan berkelanjutan yang mampu menutupi bentang yang besar. Gridshell dibangun dengan mendeformasi kisi datar tanpa kekakuan geser bidang, yang menciptakan struktur lengkung ganda. Beberapa studi telah dilakukan pada analisis struktur gridshell. Analisis akurat struktur gridshell, dalam hal tegangan dan perpindahan, sangat penting untuk mengurangi kerusakan.

Analisis elemen hingga (FEA) umumnya digunakan untuk analisis struktural. Namun, FEA adalah proses yang kompleks dan memakan waktu. Oleh karena itu, metode optimasi yang dikombinasikan dengan teknik berbasis data dapat menawarkan alternatif yang lebih cepat dan efisien. Strategi optimasi, seperti pemilihan material dan penyetelan parameter desain, memungkinkan para insinyur untuk meminimalkan dampak lingkungan sekaligus memastikan kinerja struktural. Dalam beberapa tahun terakhir, teknik berbasis data telah dikembangkan sebagai alternatif untuk proses simulasi yang memakan waktu. Pendekatan ini memecahkan masalah teknik struktural dengan biaya komputasi rendah dan akurasi tinggi.

*Building information modeling* (BIM) juga memainkan peran penting dalam proses konstruksi modern, khususnya dalam konteks struktur gridshell. Para insinyur dapat memodelkan, mensimulasikan, dan menganalisis struktur kompleks secara efisien dengan mengintegrasikan BIM dengan praktik konstruksi berkelanjutan dan menggabungkannya dengan teknik berbasis data. BIM memungkinkan visualisasi, koordinasi, dan kolaborasi yang lebih baik, memastikan bahwa material dan strategi konstruksi yang dipilih selaras dengan tujuan keberlanjutan sepanjang siklus hidup bangunan. Integrasi BIM dengan pendekatan pembelajaran mesin (ML) menawarkan potensi untuk menyederhanakan desain dan pemodelan prediktif, yang mengarah pada hasil yang lebih efektif dan berkelanjutan.

Kontributor utama metode berbasis data adalah ML, subset dari kecerdasan buatan (AI). Terdapat beberapa aplikasi ML yang efektif dalam rekayasa struktur. Mangalathu dan Jeon menetapkan pendekatan ML berbasis data dengan menggunakan regresi lasso untuk sambungan balok-kolom. Dalam studi lain, penulis yang sama menerapkan metode ML untuk mengklasifikasikan mode kegagalan kolom dan menemukan bahwa model jaringan saraf tiruan (ANN) berkinerja 10% lebih baik daripada analisis numerik. Yao dkk. menemukan bahwa mesin vektor pendukung (SVM) dua kelas menunjukkan akurasi estimasi yang lebih unggul dibandingkan dengan SVM satu kelas dalam investigasi mereka tentang pemetaan kerentanan tanah longsor. Chopra dkk. mempelajari efisiensi model ML, termasuk pohon keputusan (DT), hutan acak (RF), dan NN, dalam memperkirakan kekuatan tekan beton. Studi mereka menunjukkan bahwa metode NN adalah yang paling efisien, diikuti oleh metode RF. Das dkk.




memperkenalkan pendekatan berbasis data dan informasi fisika untuk memperkirakan retakan beton. Teknik ini dapat memprediksi masa pakai infrastruktur yang diharapkan sebelum memerlukan perawatan menggunakan data pemantauan waktu nyata. Mangalathu dkk. menerapkan model ML seperti XGBoost, AdaBoost, CatBoost, dan LightGBM untuk menentukan mode kegagalan seismik. Huang dan Burton menerapkan metode ML untuk mendeteksi mode kegagalan bidang pada rangka RC dengan pengisi, mengamati bahwa algoritma SVM dan adaptive boosting memberikan akurasi yang wajar. Slater dkk. menggunakan regresi linier dan non-linier untuk memprediksi kapasitas geser balok SFRC, menemukan bahwa LR menunjukkan akurasi estimasi yang lebih tinggi. Nunez dan Nehdi menyajikan model pohon regresi gradient-boosting untuk menentukan kedalaman karbonasi beton agregat daur ulang dengan berbagai aditif mineral.

Bab ini melakukan studi perbandingan pada sepuluh model ML, termasuk LR, RR, SVM, KNN, DT, RF, AdaBoost, XGBoost, CatBoost, dan LightGBM untuk memprediksi kinerja struktural gridshell. Model dengan akurasi tertinggi diidentifikasi. Dalam studi ini, dataset yang terdiri dari 400 sampel disiapkan menggunakan FEA. Sangat penting untuk memahami mengapa model ML menghasilkan estimasi tertentu dan fitur apa yang menyebabkan estimasi tersebut. Oleh karena itu, pendekatan interpretasi ML diperlukan untuk memahami perilaku metode ML. Signifikansi fitur input dalam memprediksi kinerja struktural struktur gridshell GFRP diselidiki menggunakan plot ketergantungan parsial (PDP), efek lokal terakumulasi (ALE), dan metode SHAP.

## **6.2 PROSES ANALISIS STRUKTURAL**

Kualitas dan jumlah sampel memengaruhi kinerja pendekatan ML. Sebuah basis data disiapkan oleh FEA yang terdiri dari 400 sampel berdasarkan perangkat lunak ABAQUS untuk mengembangkan algoritma ML untuk estimasi kinerja struktural. Berdasarkan geometri yang diperoleh, FEA dari setiap gridshell disiapkan, dan komponen balok B32 digunakan untuk mensimulasikan anggota, memungkinkan gaya aksial, geser, dan momen lentur dihitung secara tepat. Anggota struktural dalam gridshell didefinisikan sebagai tabung GFRP melingkar dengan ketebalan dinding 4 mm, diameter luar 50 mm,  $D = 1850 \text{ kg/m}^3$ , dan  $E = 26 \text{ GPa}$  dengan modul properti. Selanjutnya, sambungan perancah putar dari struktur disimulasikan oleh modul interaksi, yang menghambat rotasi di luar bidang dan translasi relatif antar simpul sambil memungkinkan rotasi relatif di dalam bidang. Penopang engsel dirancang untuk ujung anggota untuk membatasi gridshell. Berat peralatan dianggap  $2 \text{ kN/m}^2$  dalam FEA, dan berat sendiri struktur dijelaskan oleh percepatan gravitasi  $9.8 \text{ N/kg}$  oleh modul beban. Panjang elemen balok dibatasi hingga 200 mm oleh modul mesh dan tab mesh. Dalam studi ini, delapan variabel input, termasuk tinggi ( $H_1, H_2, H_3$ ), lebar ( $D_1, D_2, D_3$ ), panjang ( $S$ ), dan ukuran grid ( $G$ ), dipertimbangkan, seperti yang diilustrasikan pada Gambar 6.1.




**Gambar 6.1** Variabel desain gridshell.

Tabel 6.1 mengusulkan rentang parameter ini. Dua faktor kinerja struktural gridshell, termasuk prediksi tegangan  $F_1(x)$  dan prediksi rasio perpindahan terhadap berat sendiri  $F_1(x)$ , diusulkan pada bagian ini untuk mengevaluasi model ML. Dataset dibagi secara acak menjadi set pelatihan dan pengujian dengan rasio pelatihan 70% dan rasio pengujian 30%. Himpunan data pelatihan digunakan untuk melatih algoritma ML, dan himpunan data pengujian digunakan untuk menilai efisiensi algoritma tersebut.

**Tabel 6.1** Atribut Statistik dari Kumpulan Data

Atribut	Unit	Minimum	Maksimum	Rata-rata
H <sub>1</sub>	m	4	8	6
H <sub>2</sub>	m	4	8	6
H <sub>3</sub>	m	4	8	6
D <sub>1</sub>	m	14	18	16
D <sub>2</sub>	m	13	22	17.5
D <sub>3</sub>	m	16	20	18
S	m	32	37	34.5
G	m	0.5	3	1.75

Gambar 6.2 menggambarkan matriks korelasi untuk parameter input. Setiap koefisien korelasi dalam matriks mewakili kekuatan interaksi antara dua parameter. Terlihat bahwa variabel D<sub>3</sub> secara signifikan terkait (korelasi 0.87) dengan variabel D<sub>1</sub>. Selain itu, koefisien korelasi antara D<sub>1</sub> dan D<sub>2</sub> adalah 0.48. Tidak ada korelasi yang jelas untuk parameter lainnya. Berbagai model ML, seperti LR, RR, SVM, KNN, DT, RF, dan pendekatan gradient boosting, yaitu XGBoost, AdaBoost, CatBoost, dan LightGBM, telah dijalankan dengan Python untuk menemukan metode ML yang unggul. Karena sampel uji tidak digunakan untuk melatih algoritma ML, diasumsikan bahwa kinerja keseluruhan diperoleh dari set uji.



**Gambar 6.2** Matriks korelasi untuk variabel input.

### 6.3 PREDIKSI TEKANAN

Observasi ini bertujuan untuk mempertimbangkan karakteristik analisis struktural sebagai output. Karena kerusakan terjadi pada elemen yang mengalami tegangan berlebih, menjaga agar tegangan pada elemen tetap terkendali sangat penting. Oleh karena itu, keluaran pertama adalah tegangan maksimum. Tegangan pada elemen struktural dapat dinyatakan sebagai berikut:

$$\sigma_x = \frac{F_x}{A} \pm \frac{M_y}{W_y} \pm \frac{M_z}{W_z} \quad (6.1)$$

$$\tau_y = \frac{F_y}{A} \quad (6.2)$$

$$\tau_z = \frac{F_z}{A} \quad (6.3)$$

di mana  $\sigma$  dan  $\tau$  masing-masing adalah tegangan nominal dan tegangan geser;  $A$  adalah luas penampang elemen;  $F$  mewakili gaya;  $W$  menunjukkan modulus lentur penampang;  $M$  mengacu pada momen internal penampang. Akibatnya, keluaran pertama dapat dinyatakan sebagai:

$$F_1(x) = \sigma_{vmax} = \left( \sqrt{\sigma_x^2 + 3\tau_y^2 + 3\tau_z^2} \right)_{max} \quad (6.4)$$

dimana  $\sigma_{vmax}$  menunjukkan tegangan maksimum.

Sebuah studi perbandingan dilakukan oleh Python pada sepuluh model ML. Tabel 6.2 menyajikan perintah implementasi setiap model dalam Python. Scikit-learn adalah salah satu pustaka ML yang paling banyak digunakan karena keragaman, kegunaan, dan kemampuan komputasinya. SciPy dan NumPy, dua pustaka Python yang terkenal, adalah fondasi dari Scikit-learn. NumPy memfasilitasi operasi yang efektif pada metrik multidimensi dan array besar. Modul komputasi ilmiah ditawarkan oleh SciPy. Scikit-learn sering digunakan dalam kombinasi dengan alat visualisasi matplotlib. Selain itu, Scikit-learn menawarkan modul untuk optimasi hyperparameter. Pemilihan hyperparameter setiap model memiliki dampak signifikan pada kinerja model. Hyperparameter optimal dipilih dengan kombinasi metode pencarian grid dan validasi silang sepuluh kali lipat (CV) untuk mencegah overfitting.

Tabel 6.3 menyajikan nilai optimal dari setiap hyperparameter.

**Tabel 6.2** Implementasi Model ML di Python

Model	Modul Implementasi
LR	sklearn.linear_model.LinearRegression
RR	sklearn.linear_model.ridge_regression
SVM	sklearn.svm.SVR
KNN	sklearn.neighbors.KNeighborsRegressor
DT	sklearn.tree.DecisionTreeRegressor
RF	sklearn.ensemble.RandomForestRegressor
AdaBoost	sklearn.ensemble.AdaBoostRegressor
XGBoost	xgboost.XGBRegressor
CatBoost	catboost.CatBoostRegressor
LightGBM	lightgbm.LGBMRegressor

**Tabel 6.3** Parameter Hiperoptimal untuk  $F_1(x)$

Model	Konfigurasi Optimal
LR	N/A
RR	alpha = 1
SVM	kernel = RBF, C = 30, degree = 1, epsilon = 0.1
KNN	leaf_size = 10, n_neighbors = 1, p = 3
DT	max_depth = 8, min_samples_leaf = 1, min_samples_split = 2, random_state = 2
RF	max_depth = 8, max_features = 3, n_estimators = 500
AdaBoost	learning_rate = 0.1, n_estimators = 200, random_state = 0
XGBoost	colsample_bytree = 0.4, learning_rate = 0.08, max_depth = 2, n_estimators = 1000
CatBoost	depth = 6, iterations = 2000, learning_rate = 0.1
LightGBM	colsample_bytree = 0.9, learning_rate = 0.1, max_depth = 4, n_estimators = 500



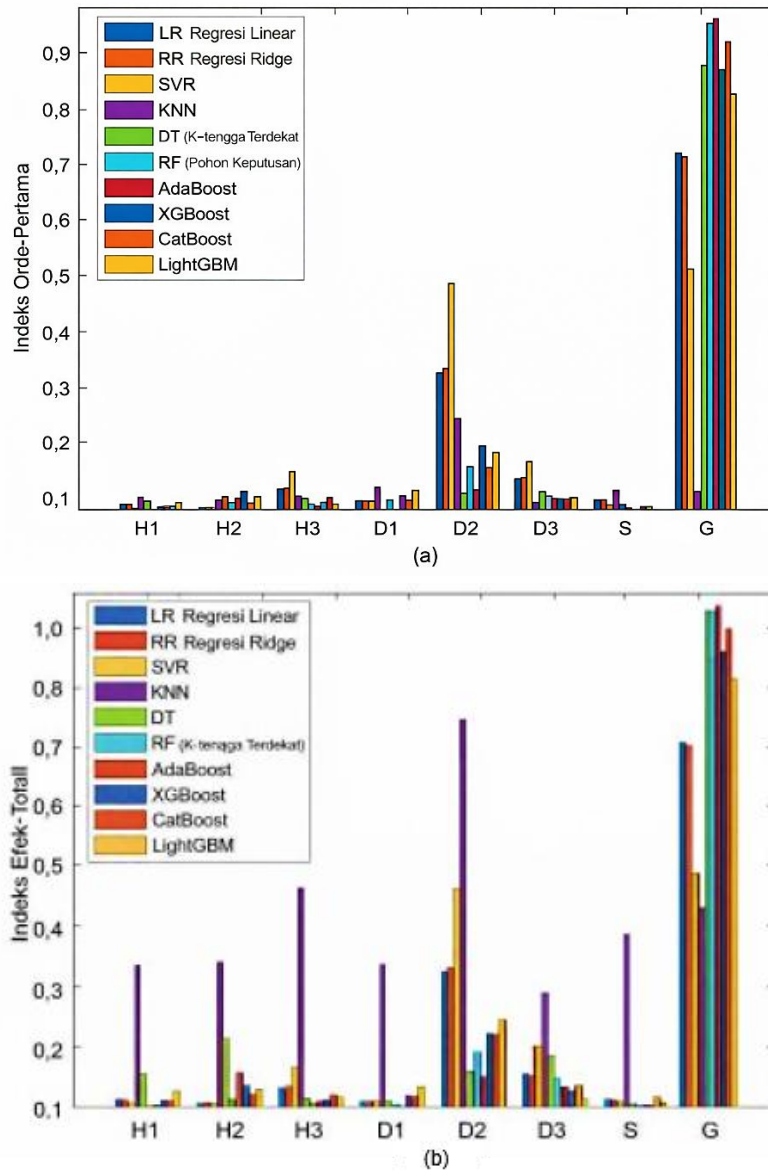
**Analisis Sensitivitas**

Indeks sensitivitas orde pertama ( $S_i$ ) dan efek total ( $S_T$ ) dari variabel input dihitung berdasarkan model regresi seperti yang ditunjukkan pada Tabel 6.4 dan Gambar 6.3. Dapat dilihat bahwa variabel input bersifat independen karena indeks orde pertama dan efek total hampir identik untuk semua metode ML kecuali model KNN dan DT.

**Tabel 6.4** Indeks Sensitivitas Orde Pertama dan Efek Total untuk  $f_1(x)$

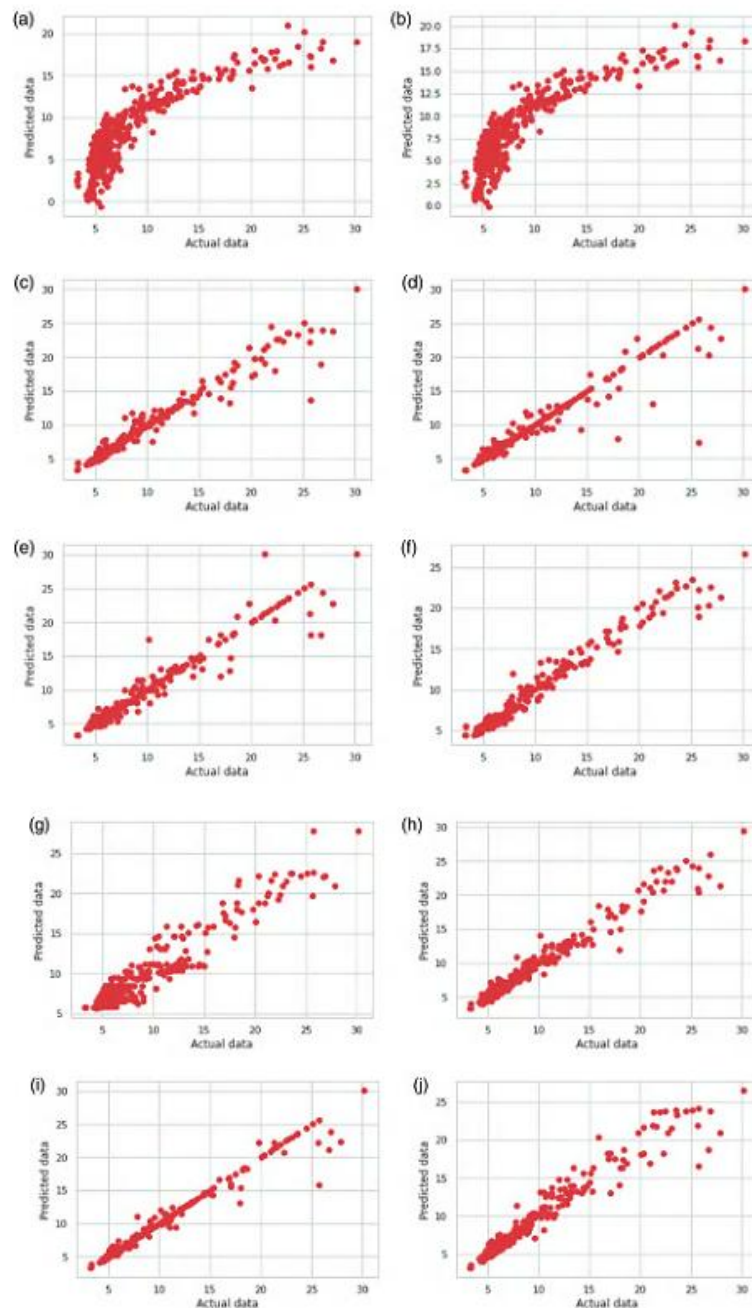
Model Regresi	S	H <sub>1</sub>	H <sub>2</sub>	H <sub>3</sub>	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	S	G	Σ
<b>LR</b>	$S_i$	0.0059	0.0023	0.0289	0.0112	0.2408	0.0600	0.0175	0.6302	0.9971
	$S_T$	0.0064	0.0023	0.0310	0.0112	0.2439	0.0589	0.0170	0.6300	1.0012
<b>RR</b>	$S_i$	0.0059	0.0023	0.0289	0.0116	0.2468	0.0609	0.0173	0.6232	0.9972
	$S_T$	0.0063	0.0023	0.0310	0.0116	0.2499	0.0599	0.0168	0.6230	1.0012
<b>SVR</b>	$S_i$	0.0009	0.0020	0.0602	0.0109	0.4013	0.0903	0.0099	0.4174	0.9932
	$S_T$	0.0014	0.0022	0.0632	0.0110	0.4056	0.0903	0.0100	0.4189	1.0029
<b>KNN</b>	$S_i$	0.0144	0.0136	0.0177	0.0360	0.1624	0.0135	0.0405	0.0378	0.3363
	$S_T$	0.2808	0.2872	0.4072	0.2561	0.7242	0.2060	0.2857	0.3552	2.8028
<b>DT</b>	$S_i$	0.0080	0.0169	0.0103	0.0004	0.0231	0.0293	0.0048	0.7881	0.8814
	$S_T$	0.0529	0.1290	0.0144	0.0002	0.0556	0.0714	0.0061	0.9246	1.2546
<b>RF</b>	$S_i$	0.0004	0.0085	0.0062	0.0098	0.0745	0.0259	0.0014	0.8587	0.9859
	$S_T$	0.0039	0.0175	0.0040	0.0102	0.0909	0.0370	0.0044	0.8707	1.0389
<b>AdaBoost</b>	$S_i$	0.0010	0.0162	0.0015	0.0002	0.0307	0.0198	0.0003	0.8706	0.9406
	$S_T$	0.0014	0.0578	0.0081	0.0021	0.0434	0.0357	0.0009	0.9308	1.0805
<b>XGBoost</b>	$S_i$	0.0009	0.0255	0.0109	0.0212	0.1151	0.0185	0.0040	0.7835	0.9799
	$S_T$	0.0115	0.0378	0.0116	0.0250	0.1230	0.0243	0.0100	0.7877	1.0312
<b>CatBoost</b>	$S_i$	0.0030	0.0044	0.0177	0.0111	0.0777	0.0193	0.0044	0.8281	0.9660
	$S_T$	0.0096	0.0174	0.0165	0.0218	0.1233	0.0370	0.0171	0.8741	1.1171
<b>LightGBM</b>	$S_i$	0.0061	0.0157	0.0099	0.0290	0.1056	0.0195	0.0003	0.7407	0.9271
	$S_T$	0.0262	0.0292	0.0135	0.0415	0.1531	0.0200	0.0116	0.7945	1.0900





**Gambar 6.3** Analisis sensitivitas  $f_1(x)$ : (a) orde pertama dan (b) efek total.

$G$  adalah variabel yang paling berpengaruh dan  $H_1$  memiliki pengaruh yang dapat diabaikan pada  $f_1(x)$ . Dengan demikian, akurasi yang rendah mungkin diperoleh dalam prediksi output ketika pengaruh  $G$  tidak dipertimbangkan.  $D_2$  berada di peringkat kedua di antara semua variabel yang berpengaruh.  $H_1$  dan  $S$  memiliki pengaruh minimum pada  $f_1(x)$ . Ditemukan bahwa kedua variabel ini tidak signifikan. Oleh karena itu, dataset dapat disiapkan dengan mempertimbangkan variasi signifikan  $G$  dan  $D_2$  untuk meningkatkan akurasi dan mengurangi jumlah sampel dalam studi di masa mendatang.



**Gambar 6.4** Plot regresi  $f_1(x)$ : (a) LR, (b) RR, (c) SVM, (d) KNN, (e) DT, (f) RF, (g) AdaBoost, (h) XGBoost, (i) CatBoost, dan (j) LightGBM. (Bersambung)

### Model Regresi untuk Prediksi Stres

Plot regresi dari berbagai model ML ditunjukkan pada Gambar 6.4, yang mengkonfirmasi akurasi tinggi dari model CatBoost. Nilai  $R^2$  dan RMSE ditunjukkan pada Tabel 6.5. Model CatBoost menunjukkan RMSE terendah dan  $R^2$  tertinggi (0.930). Oleh karena itu, CatBoost dipertimbangkan dalam subbagian berikut.

### Metode yang dapat Diinterpretasikan untuk Prediksi Stres

Berdasarkan kontribusi setiap fitur pada setiap pohon dalam model, Gambar 6.5 menampilkan pentingnya parameter dalam pengembangan model CatBoost. Parameter input


$G$  adalah fitur yang paling penting, diikuti oleh parameter  $D_2$ . Variabel yang paling tidak penting adalah  $H_3$ , diikuti oleh variabel  $S$ . Namun, tidak mungkin untuk menentukan apakah variabel input memiliki efek negatif atau positif pada plot kepentingan relatif. Plot PDP dan ALE adalah satu-satunya cara untuk menentukan pengaruh ini, seperti yang ditunjukkan pada Gambar 6.6 dan 6.7, masing-masing. Setiap grafik menggambarkan variasi estimasi metode CatBoost dibandingkan dengan rata-rata estimasi ketika parameter input diubah. Selain itu, grafik tersebut menyajikan ambang batas perubahan fitur input yang menyebabkan prediksi model berubah.

PDP adalah pendekatan interpretasi global yang diimplementasikan pada model CatBoost oleh modul `sklearn.inspection` di Python dan menampilkan sifat hubungan antara fitur dan target seperti monotonik, eksponensial, dan linier. Plot ALE dari model CatBoost diperoleh dengan pustaka `Alibi` di Python. PDP bertujuan untuk menampilkan hasil model rata-rata  $F_1(x)$  dalam hal nilai-nilai estimator yang berbeda di seluruh rentang parameter.

**Tabel 6.5** Kinerja Model Regresi Berbasis ML untuk Prediksi  $F_1(x)$  pada Gridshell

Metode Regresi	R <sup>2</sup> Rata-rata	RMSE Rata-rata
LR	0.124	2.515
RR	0.120	2.514
SVM	0.371	2.727
KNN	0.822	1.682
DT	0.779	1.750
RF	0.871	1.342
AdaBoost	0.593	1.824
XGBoost	0.905	1.126
CatBoost	0.930	1.124
LightGBM	0.890	1.278

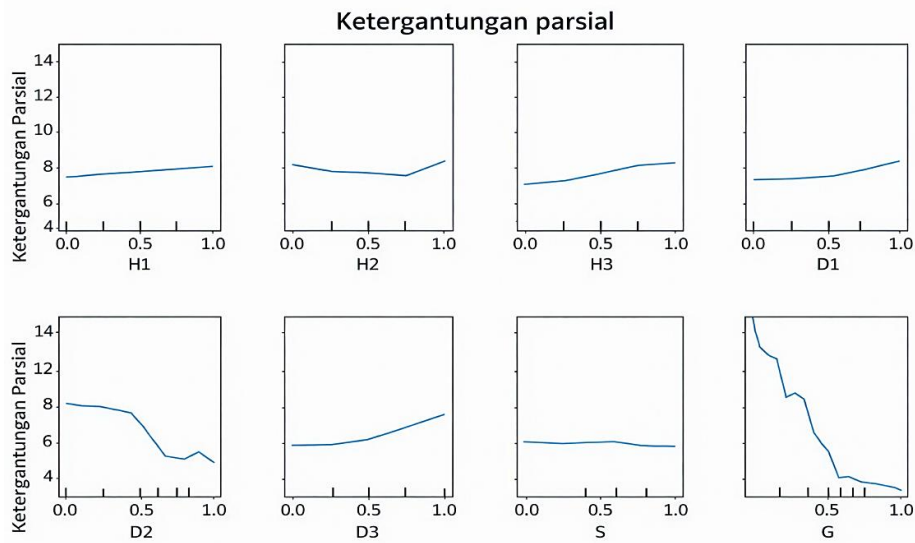
Sebaliknya, ALE menyajikan hasil rata-rata pada rentang parameter tertentu. Hasilnya menunjukkan bahwa plot ALE dan PDP memiliki tren yang hampir identik. Parameter  $G$  sangat penting, dan peningkatan  $G$  menurunkan nilai  $F_1(x)$ , seperti yang diilustrasikan pada Gambar 6.6 dan 6.7. Selain itu, parameter terpenting kedua,  $D_2$ , berdampak negatif pada prediksi  $F_1(x)$ . Nilai  $F_1(x)$  menurun seiring dengan peningkatan  $D_2$ . Selain itu, nilai  $F_1(x)$  meningkat ketika  $D_3$  melebihi nilai median.  $H_2$  tidak secara signifikan mempengaruhi output hingga mencapai 75%. Parameter input  $H_3$  dan  $S$  memiliki dampak paling kecil pada  $F_1(x)$ , yang juga ditunjukkan pada Gambar 6.5. Terdapat hubungan linier antara  $H_1$  dan  $F_1(x)$ . Secara umum,  $H_1, H_2, H_3, D_1$ , dan  $D_3$  memiliki pengaruh positif, sedangkan  $D_2, S$ , dan  $G$  berpengaruh negatif terhadap  $F_1(x)$ .




**Gambar 6.5** Faktor kepentingan CatBoost untuk  $f_1(x)$ .

SHAP adalah kumpulan penjelas yang diimplementasikan pada model CatBoost oleh pustaka Shap di Python dan mendekati nilai Shapley. Plot ringkasan SHAP ditunjukkan pada Gambar 6.8a, dengan setiap titik mewakili nilai Shapley untuk parameter. Gambar 6.8a menunjukkan bahwa setiap baris berisi jumlah sampel yang sama. Nilai Shapley dan variabel input masing-masing merupakan absis dan ordinat dari plot ini. Variabel diatur dalam urutan menurun berdasarkan kepentingannya, sedangkan variabel esensial terletak di bagian atas. Warna merah menunjukkan nilai variabel yang tinggi, sedangkan warna biru menunjukkan nilai variabel yang rendah. Rentang nilai yang meningkatkan nilai SHAP dan dengan demikian estimasi terkait ditunjukkan oleh warna merah.


Dapat dilihat bahwa peningkatan variabel  $G$ ,  $D_2$ , dan  $S$  menyebabkan penurunan nilai SHAP, dan  $F_1(x)$  juga menurun. Sebaliknya, peningkatan  $D_3$ ,  $H_3$ ,  $D_1$ ,  $H_2$ , dan  $H_1$  menyebabkan peningkatan nilai  $F_1(x)$ . Faktor signifikansi global digambarkan pada Gambar 6.8b sebagai rata-rata nilai absolut SHAP untuk setiap faktor. SHAP menentukan bahwa parameter input  $G$  adalah parameter yang paling kritis, sebanding dengan kesimpulan dari SA, variabel signifikansi CatBoost, ALE, dan PDP. Gambar 6.9 menggambarkan bahwa SHAP menyajikan grafik ketergantungan yang merupakan plot sebaran nilai SHAP suatu parameter dengan parameter lain. Warna pada Gambar 6.9 mencerminkan dampak interaksi variabel lain dengan nilai sumbu horizontal. Dapat dilihat bahwa sebagian besar memiliki perilaku non-linier.



Gambar 6.6 PDP variabel input untuk  $f_1(x)$ .



Gambar 6.7 ALE dari variabel input untuk  $f_1(x)$ .



Gambar 6.8 Plot SHAP untuk  $f_1(x)$  dari gridshell: (a) nilai Shapley dan (b) faktor kepentingan global.

Pengaruh  $D_2$  terhadap  $H_1$  ditunjukkan pada Gambar 6.9a. Jelas bahwa untuk semua nilai  $H_1$  kecuali 7m, nilai SHAP meningkat seiring dengan peningkatan  $D_2$ . Selain itu, efek positif terutama dapat diamati pada kasus  $D_1$  dan  $D_2$ , seperti yang diilustrasikan pada Gambar 6.9d. Gambar 6.9g menunjukkan bahwa  $G$  secara negatif mempengaruhi nilai SHAP untuk parameter input  $S$ . Efek positif  $D_2$  meningkat seiring dengan peningkatan  $G$ , berdasarkan Gambar 6.9h. Plot lainnya menunjukkan bahwa untuk variabel lain, nonlinieritas meningkat. Perlu dicatat bahwa plot PDP dan ALE tidak dapat digunakan untuk inferensi semacam ini.

#### 6.4 PREDIKSI RASIO PERGESERAN TERHADAP BERAT SENDIRI

Output kedua adalah rasio pergeseran maksimum terhadap berat sendiri dari struktur cangkang-jaringan. Berat sendiri dari cangkang-jaringan dapat didefinisikan sebagai:

$$W = \sum_{i=1}^k \rho A_i l_i \quad (6.5)$$

di mana  $l_i$  mengacu pada panjang elemen;  $A_i$  menunjukkan luas penampang elemen;  $\rho$  mewakili densitas material. Perpindahan dapat diukur sebagai:

$$d_i = \sqrt{x_i^2 + y_i^2 + z_i^2} \quad (6.6)$$

di mana  $x_i, y_i, z_i$  adalah perpindahan sepanjang sumbu  $x, y$ , dan  $z$ . Dengan demikian, keluaran kedua dapat didefinisikan sebagai berikut:

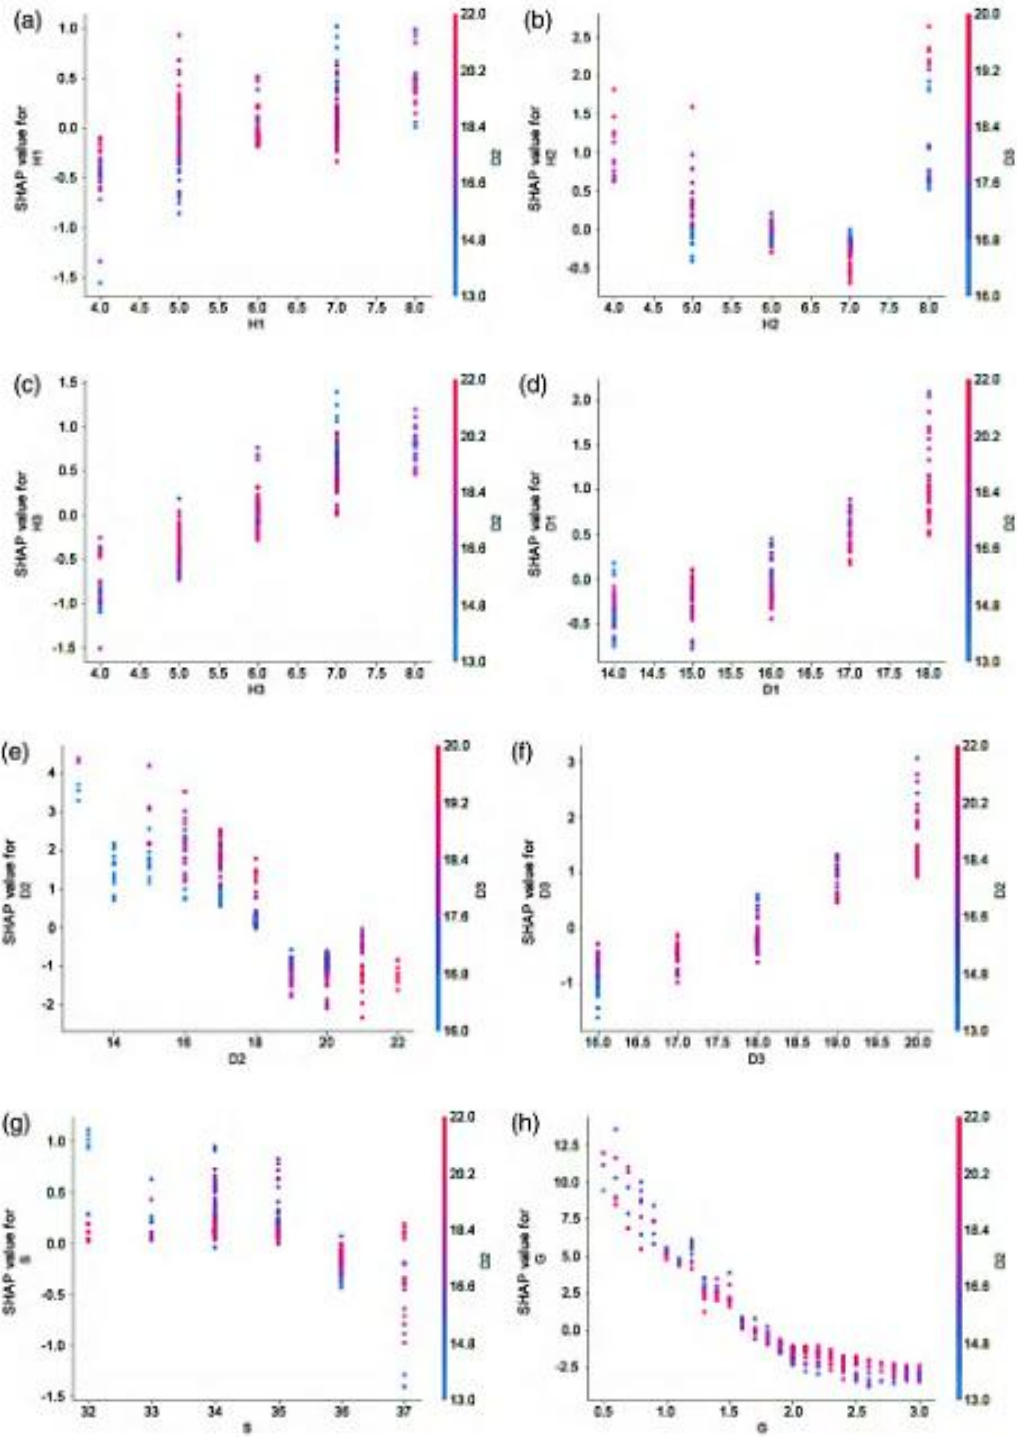
$$F_2(x) = \frac{d_{imax}}{W} \quad (6.7)$$

dimana  $d_{imax}$  adalah perpindahan nodal maksimum.

**Tabel 6.6** Parameter Hiperoptimal untuk  $F_2(x)$

Model	Konfigurasi Optimal
LR	Tidak Ada
RR	Alpha = 100
SVM	Kernel = RBF, C = 40, degree = 1, epsilon = 0.01
KNN	leaf_size = 20, n_neighbors = 1, p = 1
DT	max_depth = 8, min_samples_leaf = 1, min_samples_split = 2, random_state = 2
RF	max_depth = 9, max_features = 3, n_estimators = 1000
AdaBoost	n_estimators = 200, random_state = 2, learning_rate = 0.1
XGBoost	colsample_bytree = 0.9, learning_rate = 0.08, max_depth = 4, n_estimators = 1000
CatBoost	depth = 6, iterations = 2000, learning_rate = 0.05

Model	Konfigurasi Optimal
LightGBM	colsample_bytree = 0.9, learning_rate = 0.5, max_depth = 5, n_estimators = 1000



**Gambar 6.9** Plot ketergantungan parsial SHAP untuk  $f_1(x)$ : (a) H1-D2; (b) H2-D3; (c) H3-D2; (d) D1-D2; (e) D2-D3; (f) D3-D2; (g) S-D2; (h) G-D2.

Langkah pertama untuk membangun model regresi adalah inialisasi. Penyesuaian parameter hiper dari model ML dilakukan dengan pendekatan pencarian grid dan CV sepuluh



kali lipat untuk menghindari overfitting. Model ML disesuaikan dengan data pelatihan pertama selama proses CV sepuluh kali lipat dan dievaluasi berdasarkan data uji pertama. Untuk lipatan kedua, skor baru diperoleh dengan kumpulan data pelatihan dan pengujian lainnya. Prosedur ini diulangi 10 kali dan skor rata-rata dari 10 lipatan memberikan hasil yang dapat diandalkan. CV sepuluh kali lipat digunakan dengan pendekatan pencarian grid untuk mencari grid parameter hiper dan menghasilkan hasil terbaik. Pencarian grid berfungsi dengan menyesuaikan pada data pelatihan dan memberi skor pada data pengujian, seperti model ML lainnya.

Perbedaan utamanya adalah pendekatan pencarian grid menyelidiki semua parameter hiper sebelum model dibuat. Akibatnya, nilai-nilai dengan kinerja terbaik dipilih sebagai parameter hiper dari pendekatan ML. Tabel 6.6 menunjukkan nilai optimal parameter hiper untuk setiap algoritma ML. Kemudian, model disesuaikan dengan nilai-nilai yang diperoleh. Setelah itu, prediksi dibuat dan dibandingkan dengan set data uji. Terakhir, hasil dan grafik diekstrak.

### **Analisis Sensitivitas**

Dampak variabel-variabel yang mempengaruhi  $f_2(x)$  diselidiki dengan melakukan SA, seperti yang ditunjukkan pada Tabel 6.7 dan Gambar 6.10. Indeks efek total lebih tinggi daripada indeks orde pertama model KNN dan DT; dengan demikian, variabel-variabel tersebut berkorelasi dalam kedua model ini. Terbukti bahwa  $D_2$  adalah variabel yang paling sensitif untuk semua model ML.

**Tabel 6.7** Indeks Sensitivitas Efek Orde Pertama dan Total untuk  $f_2(x)$

Model Regresi	S	H <sub>1</sub>	H <sub>2</sub>	H <sub>3</sub>	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	S	G	Σ (Jumlah)
LR	S <sub>i</sub>	0.0000	0.0014	0.0301	0.0903	0.7737	0.0529	0.0043	0.0467	0.9997
	S <sub>r</sub>	0.0001	0.0013	0.0292	0.0899	0.7743	0.0529	0.0044	0.0466	0.9992
RR	S <sub>i</sub>	0.0000	0.0003	0.0313	0.0718	0.8100	0.0563	0.0177	0.0102	0.9979
	S <sub>r</sub>	0.0001	0.0003	0.0307	0.0715	0.8122	0.0563	0.0179	0.0101	0.9994
SVR	S <sub>i</sub>	0.0008	0.0002	0.0134	0.0780	0.7937	0.0695	0.0017	0.0286	0.9862
	S <sub>r</sub>	0.0020	0.0018	0.0148	0.0789	0.8030	0.0732	0.0060	0.0283	1.0084
KNN	S <sub>i</sub>	0.0122	0.0251	0.0453	0.0317	0.4166	0.0517	0.0313	0.0366	0.6508
	S <sub>r</sub>	0.2264	0.2290	0.2656	0.2516	0.7916	0.2504	0.2624	0.1860	2.4634
DT	S <sub>i</sub>	0.0020	0.0065	0.0089	0.0496	0.4186	0.0112	0.0319	0.0523	0.5813
	S <sub>r</sub>	0.0070	0.0367	0.1076	0.3780	0.7181	0.0342	0.0964	0.2282	1.6066
RF	S <sub>i</sub>	0.0020	0.0128	0.0347	0.0620	0.5918	0.0942	0.0793	0.0361	0.9133
	S <sub>r</sub>	0.0054	0.0418	0.0491	0.0812	0.7003	0.1193	0.1257	0.0422	1.1653
AdaBoost	S <sub>i</sub>	0.0032	0.0111	0.0704	0.0358	0.5738	0.0589	0.0462	0.0372	0.8369
	S <sub>r</sub>	0.0031	0.0617	0.1842	0.0688	0.7483	0.1094	0.0924	0.0904	1.3587
XGBoost	S <sub>i</sub>	0.0129	0.0185	0.0488	0.0322	0.5824	0.0290	0.0169	0.0457	0.7868
	S <sub>r</sub>	0.0203	0.0982	0.0965	0.1283	0.7807	0.0677	0.0382	0.0590	1.2893
CatBoost	S <sub>i</sub>	0.0025	0.0089	0.0412	0.0660	0.6145	0.0318	0.0323	0.0733	0.8708
	S <sub>r</sub>	0.0274	0.0588	0.0687	0.1142	0.7656	0.0574	0.0682	0.0873	1.2480


Model Regresi	S	H <sub>1</sub>	H <sub>2</sub>	H <sub>3</sub>	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	S	G	Σ (Jumlah)
LightGBM	S <sub>i</sub>	0.0057	0.0015	0.0164	0.0806	0.6205	0.0399	0.0181	0.0500	0.8331
	S <sub>r</sub>	0.0197	0.0279	0.0774	0.1301	0.7491	0.0592	0.0600	0.0862	1.2099

Dengan demikian, akurasi yang rendah mungkin diperoleh dalam prediksi output ketika pengaruh variabel ini tidak dipertimbangkan.  $H_1$  memiliki pengaruh minimum, yang menyiratkan bahwa parameter ini memiliki dampak yang relatif kecil pada  $f_1(x)$ . Tidak ada perbedaan signifikan dalam pengaruh parameter desain lainnya. Oleh karena itu, dataset dapat disiapkan dengan mempertimbangkan variasi signifikan  $D_2$  untuk meningkatkan akurasi dan mengurangi jumlah sampel dalam studi selanjutnya.

### **Model Regresi untuk Prediksi Rasio Pergeseran terhadap Berat Sendiri**

Gambar 6.11 menunjukkan plot regresi model ML untuk  $F_2(x)$  yang mengkonfirmasi efisiensi tinggi model CatBoost. Tabel 6.8 menyajikan RMSE dan  $R^2$  untuk menilai kinerja sepuluh algoritma ML. Hasilnya menunjukkan bahwa metode CatBoost adalah model terbaik dengan RMSE terendah (0.120) dan  $R^2$  tertinggi (0.966). Akibatnya, pendekatan CatBoost dipilih dalam bab ini untuk menyelidiki pengaruh berbagai algoritma ML yang dapat diinterpretasikan.

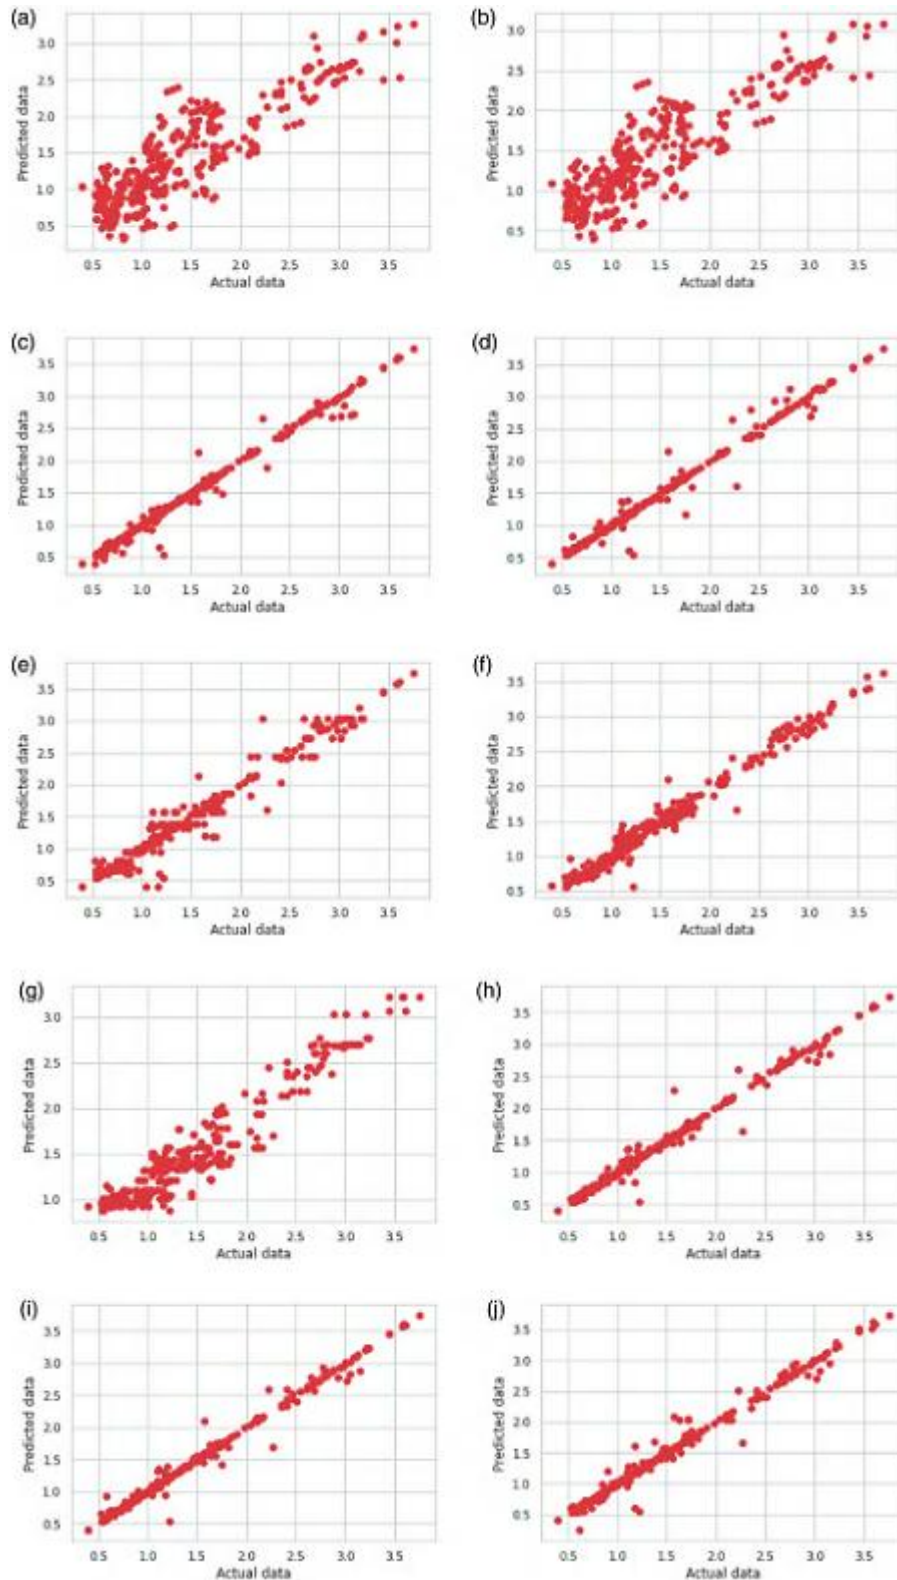
Untuk tujuan ini, pustaka CatBoost diimplementasikan dalam Python yang mencakup regressor, yaitu CatBoostRegressor. Setelah itu, pentingnya fitur metode CatBoost diikuti oleh plot PDP, ALE, dan SHAP diimplementasikan dalam Python untuk menginterpretasikan kinerja model ML. Penting untuk memantau proses dan menambahkan interpretasi guna menghindari pergeseran konsep, bias, dan kebocoran data.



**Gambar 6.10** Analisis sensitivitas  $f_2(x)$ : (A) orde pertama; (b) efek total.

**Metode yang dapat Diinterpretasikan untuk Prediksi Rasio Pergeseran terhadap Berat Badan**

Gambar 6.12 menampilkan faktor kepentingan yang dihasilkan dari model CatBoost, dengan  $D_2$ ,  $D_1$ , dan  $D_3$  sebagai variabel paling signifikan yang memengaruhi  $F_2(x)$ . Namun,  $F_2(x)$  sedikit dipengaruhi oleh variabel input H1, G, dan  $H_2$ . Gambar 6.13 dan 6.14 mengilustrasikan arah dampak parameter dan ambang batas di mana variasi estimasi dapat diselidiki dengan grafik PDP dan ALE, masing-masing. Bahkan untuk perilaku yang berkorelasi, plot ALE dan PDP menunjukkan kecenderungan yang sebanding. Dapat dilihat bahwa faktor input, kecuali  $D_1$ ,  $D_2$ , dan G, memiliki dampak kecil pada  $f_2(x)$ . Hubungan antara  $f_2(x)$  dan  $D_3$  bersifat nonlinier, dan terjadi perubahan cepat pada nilai  $f_2(x)$  ketika  $D_3$  melampaui nilai rata-rata. Nilai  $f_2(x)$  hampir identik ketika  $H_3$  melebihi 75%.




**Gambar 6.11** Plot regresi  $f_2(x)$ : (a) LR, (b) RR, (c) SVM, (d) KNN, (e) DT, (f) RF, (g) AdaBoost, (h) XGBoost, (i) CatBoost, dan (j) LightGBM. (Bersambung)

Nilai  $f_2(x)$  menurun secara linier ketika nilai  $S$  melampaui nilai tengah berdasarkan PDP. Secara umum,  $H_1$ ,  $H_3$ ,  $D_1$ ,  $D_3$ , dan  $G$  memiliki pengaruh positif, sedangkan  $D_2$  dan  $S$  berpengaruh negatif terhadap  $f_2(x)$ . Meskipun Gambar 6.12 memberi peringkat fitur, dampak fitur hanya

dapat ditentukan oleh plot ALE dan PDP. Namun, memberi peringkat fitur berdasarkan plot ALE atau PDP sangatlah menantang.

**Tabel 6.8** Kinerja Model Regresi Berbasis ML untuk Prediksi  $F_2(x)$  pada Gridshell

Metode Regresi	R <sup>2</sup> Rata-rata	RMSE Rata-rata
LR	0.649	0.372
RR	0.612	0.396
SVM	0.719	0.332
KNN	0.948	0.140
DT	0.869	0.220
RF	0.941	0.159
AdaBoost	0.788	0.290
XGBoost	0.961	0.129
CatBoost	<b>0.966</b>	<b>0.120</b>
LightGBM	0.931	0.164




**Gambar 6.12** Faktor kepentingan CatBoost untuk  $f_2(x)$ .


Gambar 6.15a menggambarkan nilai SHAP secara keseluruhan. Warna merah mewakili efek positif, sedangkan warna biru menunjukkan efek negatif. Efek positif mengacu pada peningkatan prediksi seiring dengan peningkatan faktor input.  $D_2$  memiliki efek negatif terbesar dalam memprediksi  $f_2(x)$ , sedangkan  $D_1$  memiliki dampak positif terbesar dalam memprediksi  $f_2(x)$ , seperti yang ditunjukkan pada Gambar 6.15a. Secara umum,  $D_2$ ,  $S$ , dan  $H_2$  memprediksi  $f_2(x)$  secara negatif, sedangkan  $D_1$ ,  $D_3$ ,  $H_3$ ,  $G$ , dan  $H_1$  memprediksi  $f_2(x)$  secara positif. Gambar 6.15b menggambarkan kepentingan global fitur berdasarkan nilai SHAP rata-rata dalam memprediksi  $f_2(x)$ .

Dalam memprediksi  $f_2(x)$  struktur gridshell,  $D_2$  adalah faktor terpenting, diikuti oleh  $D_1$  dan  $D_3$ , dan  $H_1$  adalah faktor yang paling tidak penting. Fitur signifikansi global dalam CatBoost menentukan  $H_3$  sebagai fitur terpenting kelima, sedangkan SHAP mendeteksi  $H_2$

sebagai fitur terpenting kelima karena perbedaan mendasar dalam penilaian faktor kepentingan. SHAP menggunakan signifikansi fitur input dalam estimasi output, sedangkan CatBoost menerapkan signifikansi fitur input dalam konstruksi pohon keputusan. Namun, fitur-fitur teratas yang dipilih oleh SHAP dan CatBoost identik.

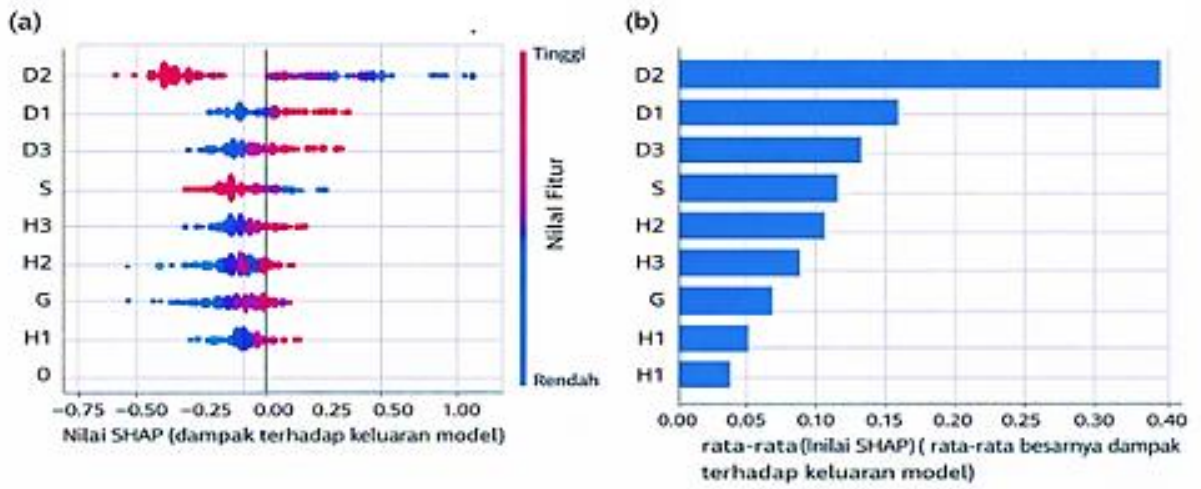


**Gambar 6.13** PDP variabel input untuk  $f_2(x)$ .

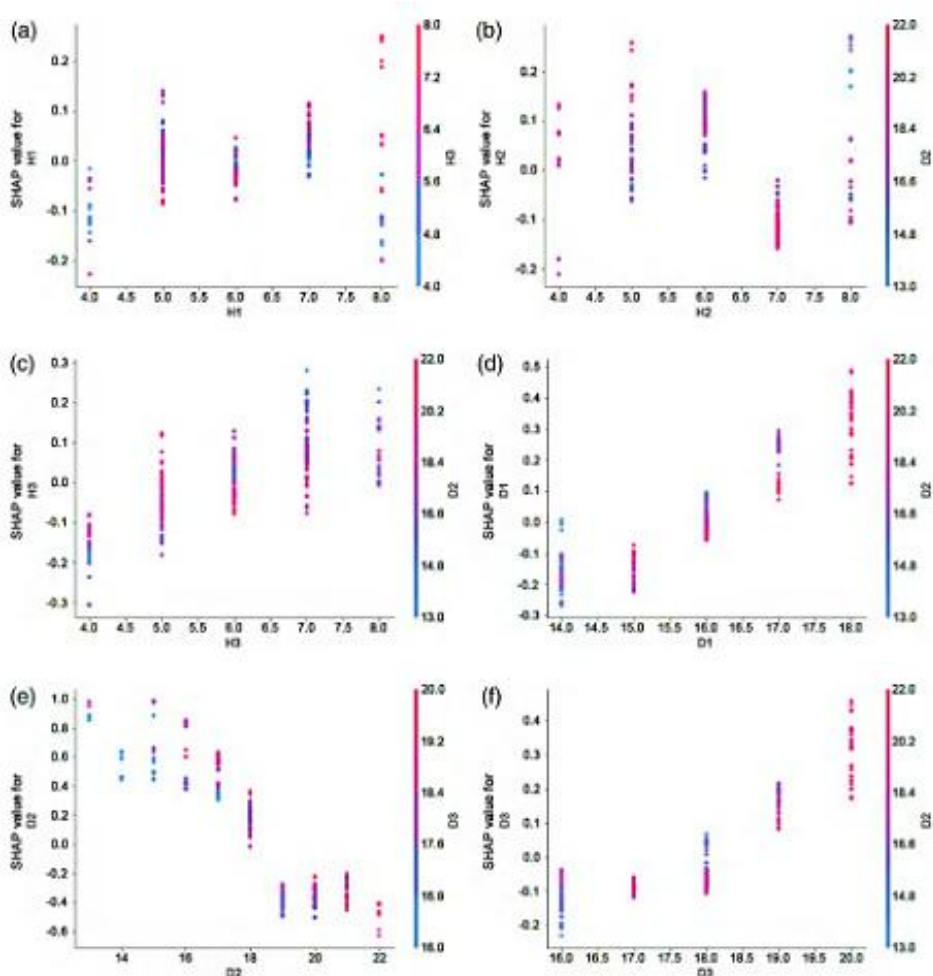


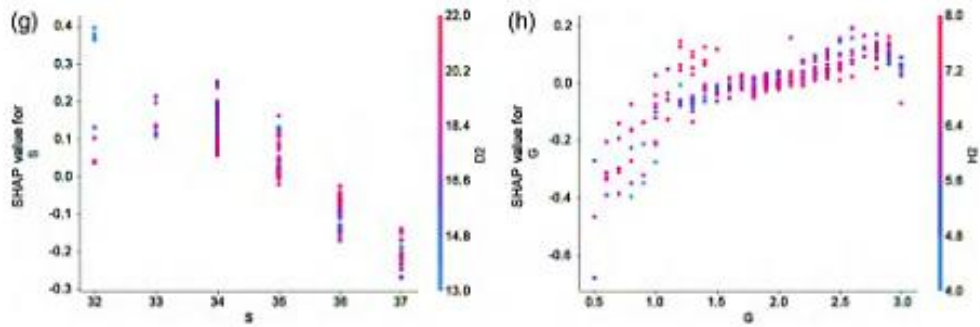
**Gambar 6.14** ALE dari variabel input untuk  $f_2(x)$ .

Plot ketergantungan parsial SHAP memberikan wawasan yang luas tentang hubungan parameter input, seperti yang ditunjukkan pada Gambar 6.16. Dapat dilihat bahwa korelasi antar fitur sebagian besar bersifat non-linier. Gambar 6.16a menampilkan efek nilai SHAP pada variabel  $H_1$  dan  $H_3$ . Jelas bahwa untuk  $H_1$  lebih dari 6 m, nilai SHAP  $H_1$  meningkat seiring dengan peningkatan  $H_3$ . Namun, trennya berbalik untuk  $H_1$  kurang dari atau sama dengan 6 m. Selanjutnya, nilai SHAP  $H_2$  lebih tinggi untuk  $D_2$  yang lebih besar ketika  $H_2$  kurang dari atau sama dengan 6 m, sedangkan trennya berbalik dan menghasilkan nilai SHAP negatif dalam kasus  $H_2$  lebih dari 6 m, seperti yang ditunjukkan pada Gambar 6.16b. Gambar 6.16c menunjukkan bahwa nilai SHAP menurun seiring dengan peningkatan  $H_3$ . Grafik lainnya menunjukkan bahwa variabel-variabel lain sering berinteraksi secara linier.



Gambar 6.15 Plot SHAP untuk  $f_2(x)$  dari gridshell: (a) nilai Shapley dan (b) faktor kepentingan global.





**Gambar 6.16** Plot ketergantungan parsial SHAP untuk  $f_2(x)$ : (a) H1-H3; (b) H2-D2; (c) H3-D2; (d) D1-D2; (e) D2-D3; (f) D3-D2; (g) S-D2; (h) G-H2. (Bersambung)

Hasil observasi menunjukkan bahwa satu pendekatan interpretasi saja tidak cukup untuk menjelaskan perilaku pendekatan ML secara keseluruhan, dan diperlukan kumpulan metode interpretasi untuk menyelidiki perilaku ML secara komprehensif.

### 6.5 PREDIKSI KINERJA GRIDSHELL GFRP: CATBOOST

Prediksi kinerja struktural memainkan peran penting dalam penilaian kerusakan struktur cangkang kisi elastis GFRP. Dalam bab ini, pendekatan ML diimplementasikan untuk memprediksi tegangan dan perpindahan maksimum struktur cangkang kisi elastis GFRP. Sepuluh algoritma ML, termasuk LR, RR, SVM, KNN, DT, RF, AdaBoost, XGBoost, CatBoost, dan LightGBM, diterapkan. Parameter input yang dipertimbangkan dalam observasi ini meliputi tiga faktor tinggi, tiga faktor lebar, panjang, dan ukuran kisi. Fitur output kinerja struktural adalah tegangan maksimum, yang diwakili sebagai  $F_1(x)$ , dan rasio perpindahan maksimum terhadap berat sendiri, yang diwakili sebagai  $F_2(x)$ . Parameter hiper terbaik untuk algoritma ML ditentukan menggunakan kombinasi pencarian kisi dan algoritma CV sepuluh kali lipat.

Hasilnya, model CatBoost mencapai akurasi tertinggi, dengan nilai  $R^2$  sebesar 0,930 untuk  $F_1(x)$  dan 0.966 untuk  $F_2(x)$ , serta nilai RMSE sebesar 1.124 untuk  $F_1(x)$  dan 0,120 untuk  $F_2(x)$ . Model LR dan RR menunjukkan akurasi terendah untuk kedua output. Oleh karena itu, Catboost diimplementasikan untuk interpretasi karena kinerjanya yang unggul. Pentingnya relatif berbagai fitur diberikan untuk pendekatan ML dengan kinerja terbaik. Terakhir, pendekatan ML yang dapat diinterpretasikan, termasuk SHAP, PDP, dan ALE, diterapkan untuk menjelaskan prediksi. Menjelaskan prediksi model ML sangat penting untuk penggunaan metode ini yang tepat. Ditemukan bahwa  $H_1$ ,  $H_2$ ,  $H_3$ ,  $D_1$ , dan  $D_3$  memiliki efek positif, sedangkan  $D_2$ ,  $S$ , dan  $G$  berpengaruh negatif terhadap  $F_1(x)$ . Selain itu,  $D_2$  dan  $S$  memiliki efek negatif, sedangkan  $H_1$ ,  $H_3$ ,  $D_1$ ,  $D_3$ , dan  $G$  secara positif mempengaruhi  $F_2(x)$ . Selanjutnya, SHAP digunakan untuk menggambarkan pentingnya setiap variabel terhadap kinerja struktural baik secara lokal maupun global. Hasil pentingnya fitur dari model CatBoost dan pendekatan SHAP menunjukkan bahwa  $G$  dan  $D_2$  adalah variabel yang paling signifikan untuk  $F_1(x)$  dan  $F_2(x)$ , masing-masing. Oleh karena itu, PDP, ALE, dan SHAP semuanya diperlukan untuk model ML yang komprehensif dan dapat diinterpretasikan.

## **BAB 7**

### **OPTIMASI STRUKTURAL CANGKANG KISI ELASTIS GFRP**

#### **7.1 OPTIMASI BENTUK GRIDSHELL DENGAN MOPSO**

Mengembangkan sumber daya yang terbatas untuk memaksimalkan manfaat dan keuntungan telah menjadi salah satu tugas paling menantang di dunia yang sangat kompetitif dan berkembang pesat saat ini. Misalnya, dalam desain teknik berbagai struktur, mencapai solusi yang layak dalam kondisi ekonomi yang sesuai diupayakan dengan menerapkan berbagai kriteria kendala. Pendekatan optimasi memberikan metode yang efektif untuk mengatasi masalah ini. Secara umum, optimasi melibatkan pemilihan kandidat terbaik dari pilihan yang tersedia. Masalah optimasi kuantitatif ditemukan di berbagai disiplin ilmu, dari sebagian besar bidang teknik hingga ekonomi. Akibatnya, matematika terapan dan ilmu teknik telah lama berfokus pada peningkatan metode dan pendekatan solusi.

Tujuan dari prosedur optimasi bentuk adalah untuk menentukan bentuk optimal dari domain desain, dengan mempertimbangkan beban dan kondisi batas. Dalam konteks ini, pemilihan metode optimasi yang tepat sangat penting. Beberapa studi tentang berbagai pendekatan optimasi telah dilakukan selama beberapa dekade terakhir. Kaveh dkk. menggunakan pendekatan optimasi kacau berdasarkan peta kacau Chebyshev untuk meningkatkan desain rangka tahan momen komposit. Kaveh dkk. menggunakan strategi adaptasi matriks kovarians untuk mengusulkan pendekatan optimasi berbasis keandalan. Kaveh dan Talatahari membandingkan enam metodologi meta-heuristik untuk desain optimal struktur kubah, menyimpulkan bahwa pendekatan koloni semut, teknik pencarian sistem muatan, dan prosedur swarm partikel mengungguli metode lainnya. Coello dkk. mengevaluasi kinerja metode multi-objektif dan menemukan bahwa optimasi *swarm partikel multi-objektif* (MOPSO) adalah yang paling efektif dalam mencakup seluruh front Pareto.

Dalam konteks ini, prosedur meta-heuristik adalah metodologi matematika yang menghilangkan batasan-batasan yang disebutkan di atas. Metode ini tidak memerlukan penggunaan fungsi tujuan kontinu atau informasi gradien dalam urutan apa pun. Metode ini terinspirasi oleh perilaku sosial, prinsip-prinsip fisik, dan aturan alam yang diamati pada manusia. Pendekatan ini didasarkan pada pola pencarian stokastik terarah dan memiliki formulasi matematika yang sederhana.

Optimasi swarm partikel (PSO), prosedur meta-heuristik berbasis populasi yang terinspirasi oleh alam, telah banyak digunakan untuk memecahkan masalah optimasi. PSO menawarkan beberapa keuntungan, termasuk pengurangan ketergantungan pada titik awal, konvergensi cepat, mekanisme eksplorasi yang efisien, sensitivitas minimal terhadap pengaturan parameter, sedikit parameter yang dibutuhkan, komputasi yang mudah, dan implementasi yang mudah. Selain itu, partikel didistribusikan secara merata di sepanjang front Pareto yang disediakan oleh MOPSO berdasarkan prinsip pembaruan partikel. Dibandingkan dengan pendekatan heuristik lainnya, manfaat ini berkontribusi pada pengurangan biaya

komputasi. Karena fitur-fitur ini, MOPSO diimplementasikan dalam bab ini untuk mendapatkan himpunan optimal Pareto.

Munculnya teknologi canggih seperti pemodelan informasi bangunan (BIM) dan kecerdasan buatan (AI) telah semakin merevolusi bidang desain struktural. BIM memfasilitasi integrasi fase desain, konstruksi, dan operasi dengan menyediakan representasi digital dari karakteristik fisik dan fungsional suatu bangunan. Ketika dikombinasikan dengan teknik AI seperti ML, para insinyur dapat memprediksi kinerja struktural, mengidentifikasi potensi masalah sejak dini dalam proses desain, dan mengoptimalkan parameter desain secara efektif. Integrasi AI dan BIM sangat bermanfaat dalam struktur kompleks, seperti gridshell, di mana pengoptimalan geometri untuk mengurangi penggunaan material dan tegangan struktural sangat penting.

## **7.2 PREDIKSI KINERJA STRUKTURAL**

Terdapat sejarah panjang penerapan model statistik berdasarkan data eksperimental atau lapangan untuk memprediksi berbagai jenis parameter yang digunakan dalam penilaian kinerja, analisis respons, dan desain struktural. Jenis model ini sangat bermanfaat ketika model berbasis fisika, yang biasanya disederhanakan untuk tujuan praktis, tidak mampu merepresentasikan mekanisme fisik yang diketahui. Dengan demikian, penting untuk memeriksa apakah penggunaan model pembelajaran mesin (ML) dapat meningkatkan kinerja prediksi dari hubungan empiris ini. Algoritma ML telah terbukti efektif untuk memprediksi dan mengevaluasi perilaku struktural dengan mengekstrak pola dari data.

Teknik optimal untuk mengevaluasi perilaku sistem yang dibangun di bawah beban ekstrem adalah simulasi respons struktural nonlinier. Observasi sebelumnya telah menggunakan ML untuk meningkatkan atau melengkapi kapasitas prediksi model respons struktural mekanistik atau berbasis fisika. Model pengganti adalah representasi statistik dari hubungan antara faktor masukan dan respons. Model ini dapat mengurangi jumlah model mekanistik yang dibutuhkan untuk beberapa aplikasi seperti optimasi kinerja dan kuantifikasi ketidakpastian dalam ruang parameter berdimensi tinggi secara komputasi.

## **7.3 OPTIMASI STRUKTURAL**

Optimasi struktural merupakan prosedur penting selama perancangan struktur cangkang grid. Setiap pengambilan keputusan dimulai dengan menetapkan dan memilih beberapa solusi yang dipilih dan disesuaikan berdasarkan beberapa tujuan. Pada dasarnya, optimasi ini mempertimbangkan kondisi statis yang harus selalu diperhitungkan bersama dalam rekayasa struktural. Optimasi harus multi-objektif dan terkendali serta memeriksa ruang pencarian untuk menemukan serangkaian solusi yang dapat diterima dalam masalah rekayasa struktural. Ketika tujuan atau kendala disajikan, metode optimasi struktural diperlukan untuk menyelesaikannya. Teknik-teknik ini dapat digunakan untuk menciptakan bentuk struktural sebagai hasil dari proses pencarian bentuk atau bentuk matematis.



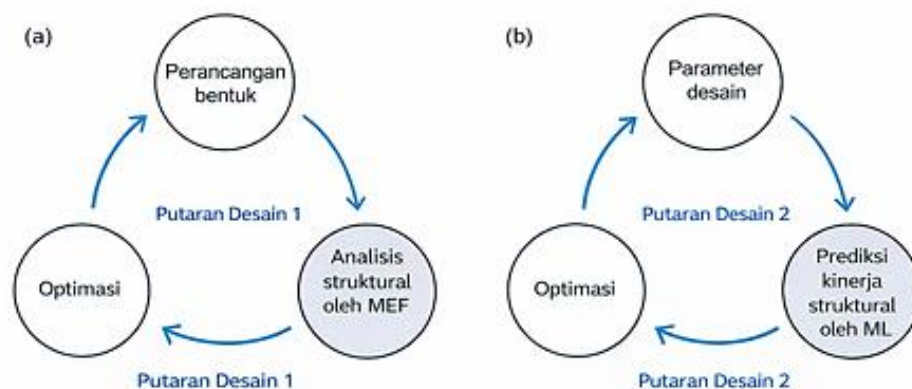
## Optimasi Bentuk

Fase optimasi bentuk dapat dicirikan sebagai berikut. Menemukan bentuk optimal untuk gridshell yang diberikan meminimalkan fungsi tujuan tertentu yang terkait dengan kinerja struktural struktur. Gambar 7.1 menampilkan siklus desain optimasi bentuk menggunakan analisis elemen hingga (FEA) dan algoritma ML. Tiga bagian membentuk masalah ini: variabel optimasi, fungsi tujuan, dan kendala. Proses optimasi bentuk diulang hingga kendala, seperti kendala ketidaksetaraan dan kesetaraan, kendala desain termasuk batas bawah dan atas variabel, dan tujuan terpenuhi. Garis Pareto diselidiki untuk beberapa fungsi tujuan untuk menilai trade-off antara tujuan yang bersaing.

### Himpunan Optimal Pareto

Teknik pencarian bentuk dan optimasi secara tradisional berfokus pada satu kriteria penting. Ini tidak akan efektif untuk sebagian besar masalah. Banyak masalah desain teknik struktural melibatkan beberapa tujuan yang bersaing. Metode optimasi tradisional digunakan untuk menemukan solusi optimal tunggal untuk masalah tujuan tunggal, seperti optimasi ukuran elemen. Teknik alternatif baru harus ditemukan untuk masalah seperti struktur gridshell, yang memiliki dampak lebih besar pada kinerja struktural, kemudahan konstruksi, dan estetika; akibatnya, solusi tunggal tidak cukup.

Dengan demikian, strategi untuk kasus ini adalah menemukan himpunan Pareto optimal dari berbagai desain grid, yang memungkinkan insinyur untuk melihat dan memahami trade-off antara tujuan yang saling bertentangan. Jika suatu desain lebih baik daripada setiap desain lainnya untuk setidaknya satu tujuan kinerja, maka dikatakan sebagai Pareto optimal. Dalam beberapa kasus, desain tersebut lebih unggul untuk semua tujuan. Pemecah multi-objektif menggunakan serangkaian tahapan iteratif atau evolusioner untuk mengidentifikasi himpunan desain Pareto optimal.



**Gambar 7.1** Tiga langkah optimasi bentuk: (a) optimasi dengan FEA dan (b) optimasi dengan ML.

#### 7.4 PERBANDINGAN ML & OPTIMASI GRIDSHELL GFRP

Bagian ini menyajikan contoh numerik dan mengungkapkan bagaimana algoritma ML digunakan dalam prediksi analisis struktural. Pertama, sebuah dataset disiapkan yang dapat digunakan algoritma ML untuk melatih model. Kemudian, metode Taguchi digunakan untuk mendapatkan parameter optimal dari algoritma ML. Setelah itu, dataset dibagi menjadi set pelatihan dan pengujian, dan algoritma ML diimplementasikan. Lima indikator kinerja digunakan selama perbandingan metode. Terakhir, hasil perbandingan disajikan.

##### Menyiapkan Dataset

Metode desain parametrik dapat diimplementasikan untuk membuat berbagai bentuk dengan memodifikasi fitur dan menghitung hasilnya. Awalnya, nilai-nilai fitur ditentukan untuk menghasilkan struktur cangkang. Kisi-kisi dihasilkan pada cangkang kontinu menggunakan pendekatan kompas pada langkah kedua. Pendekatan ini menghasilkan kisi-kisi segi empat beraturan pada cangkang apa pun. Kisi-kisi dibuat menggunakan kompas dalam pendekatan ini. Awalnya, dua kurva yang saling bersilangan pertama kali dihasilkan pada cangkang. Setelah itu, panjang jala ditentukan, yang berfungsi sebagai jari-jari kompas. Jarak antar grid ditentukan dari titik perpotongan di setiap sumbu. Perpotongan dua busur menentukan simpul. Teknik ini diulang sampai seluruh cangkang tertutup jala.

Menerapkan proses ini menghasilkan berbagai bentuk dengan menyesuaikan nilai variabel desain dengan ketinggian, kelengkungan, dan bentuk batas yang bervariasi. Setelah itu, jala dapat dihasilkan pada bentuk-bentuk ini dengan proses yang disebutkan. Kinerja struktural dari bentuk yang dihasilkan ditentukan menggunakan FEA, yang mencakup tegangan dan deformasi maksimum. Akhirnya, tabel dengan parameter desain dan fungsi tujuan terkaitnya disediakan. Pemanfaatan FEA nonlinier dalam beberapa tugas seperti proses optimasi secara signifikan meningkatkan waktu komputasi. Algoritma ML digunakan sebagai pengganti FEA untuk memprediksi fungsi tujuan guna mengurangi waktu yang dibutuhkan. Algoritma ML dilakukan menggunakan pendekatan validasi silang K-fold (CV) untuk tujuan ini.

Langkah pertama untuk mempersiapkan dataset adalah mendefinisikan parameter desain yang menghasilkan geometri yang berbeda. Untuk tujuan ini, delapan variabel masukan didefinisikan, termasuk tinggi, lebar, panjang, dan ukuran grid. Oleh karena itu, fungsi untuk membuat gridshell (yaitu,  $X$ ) diidentifikasi sebagai:

$$X = \{H_1, H_2, H_3, D_1, D_2, D_3, S, G\} \quad (7.1)$$

di mana  $H_1, H_2$ , dan  $H_3$  menunjukkan tinggi gridshell;  $D_1, D_2$ , dan  $D_3$  mewakili lebar;  $S$  dan  $G$  masing-masing adalah bentang dan ukuran grid. Gambar 7.2 menunjukkan variabel desain pada elevasi, denah, dan perspektif gridshell elastis. Empat bentuk yang dihasilkan oleh pendekatan ini ditunjukkan pada Gambar 7.3. Selain itu, Tabel 7.1 memberikan atribut statistik dari dataset.

Nilai  $H_1, H_2$ , dan  $H_3$  diambil dari himpunan  $H_1, H_2, H_3 = \{4, 5, 6, 7, 8\}$ ;  $D_1, D_2$ , dan  $D_3$  dipilih dari himpunan  $D_1 = \{14, 15, 16, 17, 18\}$ ,  $D_2 = \{13, 14, 15, 16, 17, 18, 19, 20, 21, 22\}$ , dan

$D_3 = \{16, 17, 18, 19, 20\}$ . Bentang struktural S dipilih dari himpunan  $S = \{32, 33, 34, 35, 36, 37\}$ , dan nilai  $G$  ditentukan dari 0.5 hingga 3 dengan peningkatan 0.1.

Akses terhadap data yang memadai merupakan faktor penting dalam keberhasilan kinerja ML. Sangat penting untuk memiliki sampel berkualitas tinggi yang cukup untuk mewakili distribusi sebenarnya dalam kelompok yang disampel. Hal ini memungkinkan model ML yang diterapkan untuk menemukan pola yang mendasari dan memberikan model prediksi dalam rentang masalah. Untuk tujuan ini, 360 sampel dihasilkan dari proses desain parametrik dengan memvariasikan nilai parameter desain yang ditentukan antara batas bawah dan batas atas yang diusulkan untuk setiap parameter. Gambar 7.4 menunjukkan sampel yang dihasilkan dengan metode yang disebutkan. Nilai variabel desain yang terkait dengan bentuk yang dihasilkan digambarkan pada Gambar 7.5.

**Tabel 7.1** Atribut Statistik dari Kumpulan Data

Atribut	Satuan	Minimum	Maksimum	Rata-rata
$H_1$	m	4	8	6
$H_2$	m	4	8	6
$H_3$	m	4	8	6
$D_1$	m	14	18	16
$D_2$	m	13	22	17.5
$D_3$	m	16	20	18
S	m	32	37	34.5
G	m	0.5	3	1.75

Observasi ini bertujuan untuk mempertimbangkan dua karakteristik analisis struktural sebagai keluaran. Keluaran pertama adalah tegangan maksimum karena merupakan faktor penting untuk mencegah kerusakan pada struktur cangkang elastis, yang dapat dihitung secara eksplisit untuk elemen struktur cangkang sebagai berikut:

$$\sigma_x = \frac{F_x}{A} \pm \frac{M_y}{W_y} \pm \frac{M_z}{W_z} \quad (7.2)$$

$$\tau_y = \frac{F_y}{A} \quad (7.3)$$

$$\tau_z = \frac{F_z}{A} \quad (7.4)$$

di mana tegangan nominal dan geser masing-masing dilambangkan dengan  $\sigma$  dan  $\tau$ .  $M_y$ ,  $M_z$ , dan  $W_y$ ,  $W_z$  masing-masing menunjukkan momen internal dan modulus lentur penampang dalam arah  $y$  dan  $z$ .  $F_x$  mewakili gaya aksial, dan  $F_y$ ,  $F_z$  masing-masing menunjukkan gaya geser dalam arah  $y$  dan  $z$ .  $A$  mewakili luas penampang elemen. Sangat penting untuk menjaga

tegangan pada elemen struktural tetap terkendali karena kerusakan terjadi di dalam elemen yang mengalami tegangan berlebih. Fungsi tujuan untuk tegangan dalam observasi ini adalah sebagai berikut:

$$F_1(x) = \sigma_{vmax} = \left( \sqrt{\sigma_x^2 + 3\tau_x^2 + 3\tau_y^2} \right)_{max} \quad (7.5)$$

di mana  $\sigma_x$  adalah tegangan nominal dalam arah  $x$ ;  $\tau_x$  dan  $\tau_y$  adalah tegangan geser. Keluaran kedua adalah rasio perpindahan maksimum terhadap berat sendiri. Berat sendiri ( $W$ ) ditentukan sebagai:

$$W = \sum_{i=1}^k \rho A_i l_i \quad (7.6)$$


di mana  $W$  dan  $\rho$  adalah berat gridshell, dan kerapatan elemen, masing-masing;  $A_i$  dan  $l_i$  adalah luas penampang dan panjang elemen  $i$ . Rumus untuk menghitung perpindahan adalah:

$$d_i = \sqrt{x_i^2 + y_i^2 + z_i^2} \quad (7.7)$$

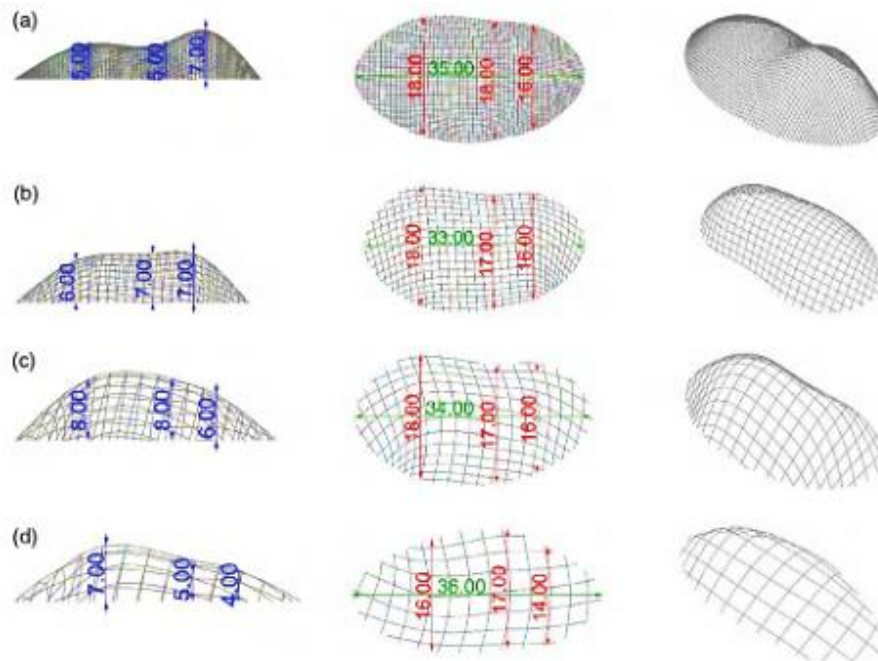
di mana  $x_i, y_i, z_i$  mewakili deformasi node- $i$  dalam arah  $x, y$ , dan  $z$ , masing-masing. Dengan demikian, fungsi tujuan kedua dapat didefinisikan sebagai berikut:

$$F_2(x) = \frac{d_{imax}}{W} \quad (7.8)$$


Di mana  $d_{imax}$  adalah perpindahan nodal maksimum. Singkatnya, studi yang disajikan mempertimbangkan dua keluaran terkait efisiensi struktural dan tegangan elemen. Keluaran pertama meminimalkan tegangan maksimum dan keluaran kedua meminimalkan rasio perpindahan maksimum terhadap berat sendiri.



**Gambar 7.2** Variabel desain struktur gridshell: (a) tampak depan, (b) tampak atas, dan (c) tampak belakang.



**Gambar 7.3** Bentuk yang dihasilkan dengan mengubah nilai parameter desain.



**Gambar 7.4** Pembentukan bentuk cangkang kisi elastis.

### **Analisis Elemen Hingga**

Pada langkah selanjutnya, kinerja struktural sampel yang dihasilkan ditentukan menggunakan FEA. Program FE serbaguna ABAQUS digunakan untuk membuat FEA. MATLAB juga digunakan untuk membuat model ML, yang memungkinkan pembuatan model dan ekstraksi data secara otomatis, akurat, dan efisien. Elemen balok B32 digunakan untuk simulasi anggota; dengan demikian, momen lentur, gaya geser, dan gaya aksial dapat dipertimbangkan. Karena perilaku linier terdeteksi sebelum kerusakan pada uji lentur, model konstitutif elastis linier digunakan untuk material polimer yang diperkuat serat kaca (GFRP). Anggota struktural cangkang kisi dijelaskan sebagai tabung GFRP melingkar dengan ketebalan dinding 4 mm, radius luar 25 mm,  $D = 1850 \text{ kg/m}^3$ , dan  $E = 26 \text{ GPa}$  dengan modul properti. Penggabungan derajat kebebasan (DOF) digunakan untuk simpul yang digabungkan dalam FEA untuk mensimulasikan bagian struktural dari konektor perancah putar yang digunakan untuk menyambungkan elemen pada persimpangannya.

DOF rotasi bidang tidak terkait, sedangkan DOF rotasi dan translasi di luar bidang digabungkan untuk sepasang simpul yang disambung melalui modul interaksi. Penopang pin ditentukan untuk ujung elemen untuk membatasi cangkang grid yang melarang translasi di ujung elemen. Berat peralatan dan struktur aksesori diasumsikan sebesar 2 kN/m<sup>2</sup>, dan percepatan gravitasi sebesar 9.8 N/kg diidentifikasi dalam FEA untuk mempertimbangkan berat sendiri struktural melalui modul beban. Panjang elemen balok dibatasi hingga 200 mm oleh modul mesh.

Gambar 7.6 menunjukkan sampel yang dianalisis oleh FEA dan tegangan dan perpindahan maksimum yang terkait. Tujuan menganalisis sampel adalah untuk mempersiapkan dataset, termasuk input dan output, untuk pelatihan dan pengujian algoritma. Dengan demikian, tabel dari hasil FEA diekstrak sebagai dataset yang akan digunakan pada langkah selanjutnya.

### **Implementasi Algoritma**

Dataset yang diperoleh, termasuk parameter desain dan output, digunakan untuk melatih model di platform MATLAB. Dengan demikian, algoritma dilatih dengan CV sepuluh kali lipat. Oleh karena itu, sepuluh putaran pelatihan dan validasi dilakukan dengan mempertimbangkan partisi yang berbeda dan rata-rata hasil yang diperoleh untuk menunjukkan kinerja algoritma ML. Teknik untuk preferensi urutan berdasarkan kesamaan dengan solusi ideal (TOPSIS) digunakan di Excel untuk menghitung nilai respons berdasarkan nilai RME,  $R$ , dan waktu eksekusi, diikuti oleh metode Taguchi, yang dilakukan di Minitab, untuk menemukan variabel optimal dari algoritma. Matriks yang dinormalisasi, matriks yang dinormalisasi berbobot, nilai ideal terbaik dan ideal terburuk, jarak Euclidean dari ideal terbaik dan ideal terburuk, dan skor kinerja masing-masing dihitung untuk mendapatkan respons TOPSIS.

Dalam observasi ini, tiga level dibuat yaitu rendah, menengah, dan tinggi untuk setiap parameter. Rentang dan level parameter PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM masing-masing disajikan dalam Tabel 7.2, 7.3, 7.4, dan 7.5. Proses kalibrasi yang diperoleh dengan metode TOPSIS dari PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM yang berkaitan dengan output pertama disajikan dalam Tabel 7.6, 7.7, 7.8, dan 7.9, masing-masing. Selanjutnya, susunan ortogonal dan respons terkaitnya yang diperoleh dengan metode TOPSIS dari PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM disajikan dalam Tabel 7.10, 7.11, 7.12, dan 7.13, masing-masing. Selain itu, Gambar 7.7, 7.8, 7.9, dan 7.10 menggambarkan rasio Taguchi untuk algoritma ML.

Hasilnya, parameter optimum dari algoritma PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM ditentukan sebagai berikut:

Parameter PSO-LSSVM untuk  $F_1(x)$ :  $C_1 = 0.5$ ,  $C_2 = 2$ ,  $W = 0.9$ ,  $PS = 50$ ,  $NOI = 100$ .

Parameter PSO-LSSVM untuk  $F_2(x)$ :  $C_1 = 0.5$ ,  $C_2 = 1$ ,  $W = 0.2$ ,  $PS = 50$ ,  $NOI = 100$ .

Parameter PIN-SVM untuk  $F_1(x)$ :  $C_1 = C_2 = 0.1$ ,  $C_3 = C_4 = 0.1$ ,  $P = 1$ .

Parameter PIN-SVM untuk  $F_2(x)$ :  $C_1 = C_2 = 1$ ,  $C_3 = C_4 = 1$ ,  $P = 3$ .


Parameter  $\epsilon$ -TSVM untuk  $F_1(x)$ :  $C_1 = C_2 = 0.01$ ,  $C_3 = C_4 = 0.01$ ,  $C_5 = C_6 = 1$ ,  $P = 6$ .

Parameter  $\epsilon$ -TSVM untuk  $F_2(x)$ :  $C_1 = C_2 = 1$ ,  $C_3 = C_4 = 0.1$ ,  $C_5 = C_6 = 1$ ,  $P = 2$ .

Parameter WL- $\epsilon$ -TSVM untuk  $F_1(x)$ :  $C_1 = C_2 = 0.01$ ,  $C_3 = C_4 = 0.1$ ,  $C_5 = C_6 = 0.01$ ,  $C_7 = C_8 = 0.01$ ,  $C_9 = C_{10} = 1$ ,  $P = 6$ .

Parameter WL- $\epsilon$ -TSVM untuk  $F_2(x)$ :  $C_1 = C_2 = 0.01$ ,  $C_3 = C_4 = 0.1$ ,  $C_5 = C_6 = 0.01$ ,  $C_7 = C_8 = 1$ ,  $C_9 = C_{10} = 0.01$ ,  $C_7 = 2$ .

Proses pelatihan dilakukan untuk mengidentifikasi korelasi antara input dan output, dan akurasi divalidasi. Untuk menentukan output pertama dan kedua, hasilnya diekstrak sesuai dengan hasil prediksi dari setiap metode.



**Gambar 7.6** Contoh FEA dengan  $H_1 = 5$ ,  $H_2 = 6$ ,  $H_3 = 6$ ,  $D_1 = 17$ ,  $D_2 = 17$ ,  $D_3 = 19$ ,  $S = 34$ ,  $G = 1.8$ : (a) tegangan maksimum = 13.1 MPa dan (b) perpindahan maksimum/w = 2.95 mm/kN.

**Tabel 7.2** Rentang dan Tingkat Parameter PSO-LSSVM

Parameter	Rentang	Rendah (1)	Sedang (2)	Tinggi (3)
$C_1$	0.5–2.0	0.5	1.0	2.0
$C_2$	0.5–2.0	0.5	1.0	2.0
W	0.2–0.9	0.2	0.5	0.9
PS	50–200	50	100	200
NOI	100–300	100	200	300

**Tabel 7.3** Rentang dan Tingkat Parameter PIN-SVM

Parameter	Rentang	Rendah (1)	Sedang (2)	Tinggi (3)
$C_1 = C_2$	0.01–1.0	0.01	0.1	1.0
$C_3 = C_4$	0.01–1.0	0.01	0.1	1.0
P	1.0–3.0	1.0	2.0	3.0

**Tabel 7.4** Rentang dan Tingkat Parameter  $\epsilon$ -TSVM

Parameter	Rentang	Rendah (1)	Sedang (2)	Tinggi (3)
$C_1 = C_2$	0.01–1.0	0.01	0.1	1.0
$C_3 = C_4$	0.01–1.0	0.01	0.1	1.0
$C_5 = C_6$	0.01–1.0	0.01	0.1	1.0
P	2.0–6.0	2.0	4.0	6.0

**Tabel 7.5** Rentang dan Tingkat Parameter WL- $\epsilon$ -TSVM

Parameter	Rentang	Rendah (1)	Sedang (2)	Tinggi (3)
$C_1 = C_2$	0.01–1.0	0.01	0.1	1.0
$C_3 = C_4$	0.01–1.0	0.01	0.1	1.0
$C_5 = C_6$	0.01–1.0	0.01	0.1	1.0
$C_7 = C_8$	0.01–1.0	0.01	0.1	1.0
$C_9 = C_{10}$	0.01–1.0	0.01	0.1	1.0
P	2.0–6.0	2.0	4.0	6.0

**Tabel 7.6** Proses Kalibrasi PSO-LSSVM

Urutan Percobaan	Parameter Algoritma					$F_1(x)$			
	1	2	3	4	5	RMSE	R	Waktu	Respons
1	1	1	1	1	1	1.1218	0.95158	116.86	1.0000
2	1	1	1	1	2	1.1267	0.95153	232.69	0.9894
3	1	1	1	1	3	1.1306	0.95152	304.31	0.9792
4	1	2	2	2	1	2.7405	0.54108	235.38	0.9890
5	1	2	2	2	2	2.7577	0.53775	438.80	0.9529
6	1	2	2	2	3	2.7577	0.53775	647.27	0.8934
7	1	3	3	3	1	2.7440	0.54031	439.05	0.9529
8	1	3	3	3	2	2.7577	0.53775	886.93	0.7967
9	1	3	3	3	3	2.7577	0.53775	1256.59	0.5883
10	2	1	2	3	1	2.6339	0.57481	519.68	0.9326
11	2	1	2	3	2	2.7195	0.54854	1038.12	0.7202
12	2	1	2	3	3	2.7293	0.54512	1549.02	0.3726
13	2	2	3	1	1	2.7353	0.54217	144.24	0.9978
14	2	2	3	1	2	2.7577	0.53775	268.26	0.9846
15	2	2	3	1	3	2.7577	0.53775	394.06	0.9627
16	2	3	1	2	1	2.8956	0.51695	262.40	0.9854
17	2	3	1	2	2	2.7577	0.53775	516.51	0.9334
18	2	3	1	2	3	2.7577	0.53775	832.55	0.8213
19	3	1	3	2	1	2.7382	0.54300	292.57	0.9811
20	3	1	3	2	2	2.7535	0.53941	588.51	0.9125
21	3	1	3	2	3	2.7355	0.54251	940.33	0.7711
22	3	2	1	3	1	2.7608	0.53730	674.31	0.8840
23	3	2	1	3	2	2.7577	0.53775	1334.87	0.5350
24	3	2	1	3	3	2.7577	0.53775	1953.51	0.0001
25	3	3	2	1	1	2.8956	0.51694	188.06	0.9942
26	3	3	2	1	2	2.7577	0.53775	354.83	0.9705
27	3	3	2	1	3	2.7577	0.53775	513.00	0.9344

**Tabel 7.7** Proses Kalibrasi PIN-SVM

Urutan Percobaan	Parameter Algoritma			$F_1(x)$			
	1	2	3	RMSE	R	Waktu	Respons
1	1	1	1	1.4791	0.94877	21.08	0.6205
2	1	2	2	1.2185	0.95007	21.22	0.6512
3	1	3	3	1.5556	0.92824	21.31	0.3833
4	2	1	2	1.2183	0.95709	21.00	0.8444
5	2	2	3	1.2039	0.94736	21.34	0.5160
6	2	3	1	1.3313	0.92000	21.10	0.6979
7	3	1	3	1.0559	0.95946	21.61	0.3816
8	3	2	1	1.3478	0.94740	21.03	0.7311
9	3	3	2	1.4921	0.92195	21.40	0.2957

**Tabel 7.8** Proses Kalibrasi  $\epsilon$ -TSVM

Urutan Percobaan	Parameter Algoritma				$F_1(x)$			
	1	2	3	4	RMSE	R	Waktu	Respons
1	1	1	1	1	1.2172	0.95709	22.61	0.6886
2	1	2	2	2	1.2325	0.94432	22.80	0.6038
3	1	3	3	3	1.6114	0.93863	22.65	0.3472
4	2	1	2	3	0.9531	0.95667	22.61	0.8488
5	2	2	3	1	1.2188	0.95006	22.52	0.7145
6	2	3	1	2	1.5678	0.93369	23.25	0.0906
7	3	1	3	2	0.9750	0.95998	22.34	0.9802
8	3	2	1	3	1.3117	0.93908	23.35	0.3610
9	3	3	2	1	1.5037	0.92171	23.23	0.1722

### Hasil Perbandingan

Seerti yang telah dibahas sebelumnya, enam algoritma ML telah diimplementasikan untuk memprediksi analisis struktural, dan kinerja prediktifnya dibahas. Algoritma dievaluasi dengan membandingkan nilai prediksi yang diperoleh dengan nilai aktual dari kedua output. Indikator kinerja digunakan untuk mengilustrasikan kinerja prediktif model. Gambar 7.11 dan 7.12 menunjukkan korelasi antara nilai prediksi dan nilai aktual dari output untuk 72 sampel pengujian. Diamati bahwa nilai prediksi pada dasarnya sesuai dengan nilai aktual, sementara WL- $\epsilon$ -TSVM memiliki akurasi tertinggi dan ANN memiliki akurasi terendah. Kinerja terbaik dicapai oleh algoritma WL- $\epsilon$ -TSVM dengan nilai  $R$  terbesar yaitu 0.97756 dan 0.99095 untuk output pertama dan kedua, masing-masing.

Untuk memeriksa kinerja algoritma, deviasi relatif rata-rata (ARD), kesalahan kuadrat rata-rata ternormalisasi (NMSE), kesalahan kuadrat rata-rata akar (RMSE), deviasi standar (SD), dan  $R$  dihitung sebagai indikator kinerja prediktif. Gambar 7.13 menggambarkan ARD, NMSE, RMSE, dan SD dari algoritma ML. Tabel 7.14 merangkum indikator kinerja yang terkait dengan

berbagai algoritma, di mana angka yang dicetak tebal menunjukkan hasil kinerja terbaik bersama dengan respons yang diperoleh oleh metode TOPSIS.

**Tabel 7.9** Proses Kalibrasi WL- $\epsilon$ -TSVM

Urutan Percobaan	Parameter Algoritma						$F_1(x)$			
	1	2	3	4	5	6	RMSE	R	Waktu	Respons
1	1	1	1	1	1	1	1.2183	0.95707	20.97	0.9301
2	1	1	1	1	2	2	0.9747	0.95998	20.90	0.9916
3	1	1	1	1	3	3	0.9526	0.95668	20.92	0.9956
4	1	2	2	2	1	1	1.2178	0.95007	21.52	0.8862
5	1	2	2	2	2	2	1.2312	0.94435	21.59	0.8757
6	1	2	2	2	3	3	1.3264	0.93913	21.17	0.8933
7	1	3	3	3	1	1	1.5017	0.92184	21.57	0.8211
8	1	3	3	3	2	2	1.5663	0.93377	20.99	0.8355
9	1	3	3	3	3	3	1.6098	0.93869	21.27	0.8129
10	2	1	2	3	1	1	1.2201	0.95685	23.09	0.6633
11	2	1	2	3	2	2	0.9719	0.96000	26.90	0.1688
12	2	1	2	3	3	3	0.9478	0.95680	23.66	0.5865
13	2	2	3	1	1	1	1.2171	0.95017	22.49	0.7541
14	2	2	3	1	2	2	1.2293	0.94456	22.62	0.7339
15	2	2	3	1	3	3	1.3242	0.93946	22.69	0.7154
16	2	3	1	2	1	1	1.4694	0.92290	22.62	0.7084
17	2	3	1	2	2	2	1.5357	0.93440	22.79	0.6766
18	2	3	1	2	3	3	1.5793	0.93911	23.81	0.5246
19	3	1	3	2	1	1	1.2014	0.95688	24.27	0.4780
20	3	1	3	2	2	2	0.9675	0.96002	22.05	0.8319
21	3	1	3	2	3	3	0.9379	0.95702	22.02	0.8368
22	3	2	1	3	1	1	1.1386	0.95032	21.86	0.8515
23	3	2	1	3	2	2	1.1394	0.94631	23.26	0.6414
24	3	2	1	3	3	3	1.2170	0.94126	21.98	0.8271
25	3	3	2	1	1	1	1.2947	0.92818	21.76	0.8449
26	3	3	2	1	2	2	1.3555	0.93811	22.27	0.7709
27	3	3	2	1	3	3	1.3970	0.94210	21.81	0.7127

**Tabel 7.10** Proses Kalibrasi PSO-LSSVM

Urutan Percobaan	Parameter Algoritma					$F_2(x)$			
	1	2	3	4	5	RMSE	R	Waktu	Respon
1	1	1	1	1	1	0.1328	0.98828	119.09	1.0000
2	1	1	1	1	2	0.1341	0.98799	211.48	0.9924
3	1	1	1	1	3	0.1358	0.98763	305.22	0.9804
4	1	2	2	2	1	0.4924	0.7919	231.02	0.9903

5	1	2	2	2	2	0.4957	0.79067	447.44	0.9539
6	1	2	2	2	3	0.4957	0.79067	662	0.8949
7	1	3	3	3	1	0.4993	0.78911	439.52	0.9556
8	1	3	3	3	2	0.4957	0.79067	878.34	0.8123
9	1	3	3	3	3	0.4957	0.79067	1278.23	0.5987
10	2	1	2	3	1	0.1217	0.9899	462.77	0.9504
11	2	1	2	3	2	0.1208	0.9897	903.87	0.8011
12	2	1	2	3	3	0.1207	0.9893	1420.51	0.5035
13	2	2	3	1	1	0.4938	0.79139	143.14	0.9984
14	2	2	3	1	2	0.4957	0.79067	274.62	0.9848
15	2	2	3	1	3	0.4957	0.79067	400.64	0.9637
16	2	3	1	2	1	0.4996	0.78895	269.7	0.9855
17	2	3	1	2	2	0.4957	0.79067	532.09	0.9334
18	2	3	1	2	3	0.4957	0.79067	872.17	0.815
19	3	1	3	2	1	0.4857	0.794	295.33	0.9819
20	3	1	3	2	2	0.4956	0.79047	641.81	0.9014
21	3	1	3	2	3	0.4922	0.79186	943.23	0.7831
22	3	2	1	3	1	0.4943	0.7912	673.09	0.8913
23	3	2	1	3	2	0.4957	0.79067	1289.3	0.5916
24	3	2	1	3	3	0.4957	0.79067	2012.43	0.0000
25	3	3	2	1	1	0.5266	0.76468	193.02	0.9943
26	3	3	2	1	2	0.4957	0.79067	364.47	0.9706
27	3	3	2	1	3	0.4957	0.79067	519.85	0.9366

Sebagai hasilnya, model WL- $\epsilon$ -TSVM mencapai  $R$  tertinggi sebesar 0.97756, NMSE terendah sebesar 0.0686, dan RMSE sebesar 1.0069 untuk output pertama dan  $R$  tertinggi sebesar 0.99095, dan NMSE terendah sebesar 0.0220 dan RMSE sebesar 0.1172 untuk output kedua. Selain itu, nilai ARD dan SD terendah masing-masing diperoleh oleh  $\epsilon$ -TSVM dan PSO-LSSVM untuk output pertama, dan WLSSVM dan PSO-LSSVM untuk output kedua.

**Tabel 7.11** Proses Kalibrasi PIN-SVM

Urutan Percobaan	Parameter Algoritma			$F_2(x)$			
	1	2	3	RMSE	$R$	Waktu	Respon
1	1	1	1	0.1201	0.99119	21.22	0.4489
2	1	2	2	0.1435	0.98839	21.40	0.0606
3	1	3	3	0.1416	0.98576	21.06	0.7920
4	2	1	2	0.1417	0.98847	21.25	0.3612
5	2	2	3	0.1552	0.98487	20.99	0.8508
6	2	3	1	0.1468	0.98357	21.30	0.2400
7	3	1	3	0.1400	0.98785	21.20	0.4783
8	3	2	1	0.1206	0.99129	20.98	0.9974
9	3	3	2	0.1292	0.98965	21.05	0.8328

**Tabel 7.12** Proses Kalibrasi  $\epsilon$ -TSVM

Urutan Percobaan	Parameter Algoritma				$F_2(x)$			
	1	2	3	4	RMSE	R	Waktu	Respon
1	1	1	1	1	0.1417	0.98847	22.43	0.9893
2	1	2	2	2	0.1583	0.98253	23.17	0.6368
3	1	3	3	3	0.2110	0.96272	22.86	0.7748
4	2	1	2	3	0.1493	0.98135	24.23	0.1167
5	2	2	3	1	0.1435	0.98388	23.06	0.6923
6	2	3	1	2	0.1617	0.97923	24.41	0.0576
7	3	1	3	2	0.1407	0.98679	22.94	0.7516
8	3	2	1	3	0.1524	0.98129	22.63	0.9009
9	3	3	2	1	0.1291	0.98967	22.69	0.8743

Namun, akurasi dapat dimaksimalkan dengan mengembangkan dataset pelatihan yang lebih luas. Oleh karena itu, dataset yang lebih besar di bawah beban lingkungan yang kompleks akan dihasilkan untuk meningkatkan akurasi dan penerapannya dalam studi di masa mendatang.

Disimpulkan bahwa algoritma WL- $\epsilon$ -TSVM memiliki akurasi terbaik dalam mendeteksi kedua output menurut hasil yang diperoleh dari perbandingan metode yang diusulkan. Terlihat bahwa kinerja prediksi metode PSO-LSSVM relatif rendah dibandingkan dengan algoritma WL- $\epsilon$ -TSVM. Gambar 7.14 menunjukkan perbandingan nilai aktual dan nilai yang diperoleh oleh algoritma ANN, WLSSVM, PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM untuk kedua output, yang menegaskan akurasi yang lebih tinggi dari algoritma WL- $\epsilon$ -TSVM. Karena metode WL- $\epsilon$ -TSVM memiliki kinerja yang lebih baik dibandingkan dengan model lain, metode ini direkomendasikan untuk prediksi perilaku struktural dalam proses optimasi, yang didasarkan pada hasil yang diperoleh oleh metode TOPSIS. Algoritma ANN tidak disarankan karena nilai R yang rendah (0.96859 untuk output pertama dan 0.97961 untuk output kedua) diperoleh.

**Tabel 7.13** Proses Kalibrasi WL- $\epsilon$ -TSVM


Urutan Percobaan	Parameter Algoritma						$F_2(x)$			
	1	2	3	4	5	6	RMSE	R	Waktu	Respon
1	1	1	1	1	1	1	0.1417	0.98847	21.10	0.9452
2	1	1	1	1	2	2	0.1407	0.98679	20.87	0.9883
3	1	1	1	1	3	3	0.1493	0.98138	20.98	0.9699
4	1	2	2	2	1	1	0.1440	0.98838	20.96	0.9754
5	1	2	2	2	2	2	0.1587	0.98254	21.07	0.9494
6	1	2	2	2	3	3	0.1525	0.98131	21.23	0.9144
7	1	3	3	3	1	1	0.1320	0.98969	21.36	0.8852
8	1	3	3	3	2	2	0.1630	0.97931	21.16	0.9289
9	1	3	3	3	3	3	0.2116	0.96285	21.18	0.9120

Urutan Percobaan	Parameter Algoritma						$F_2(x)$			
	1	2	3	4	5	6	RMSE	R	Waktu	Respon
10	2	1	2	3	1	1	0.1455	0.98847	21.97	0.7389
11	2	1	2	3	2	2	0.1455	0.98682	22.77	0.5411
12	2	1	2	3	3	3	0.1520	0.98159	23.48	0.3596
13	2	2	3	1	1	1	0.1656	0.98839	22.26	0.6675
14	2	2	3	1	2	2	0.1762	0.98257	22.92	0.5024
15	2	2	3	1	3	3	0.1637	0.98142	22.88	0.5129
16	2	3	1	2	1	1	0.1284	0.98982	22.66	0.5690
17	2	3	1	2	2	2	0.1592	0.97991	22.84	0.5231
18	2	3	1	2	3	3	0.2073	0.96396	22.81	0.5291
19	3	1	3	2	1	1	0.1372	0.98845	22.64	0.5739
20	3	1	3	2	2	2	0.1225	0.98600	24.82	0.0461
21	3	1	3	2	3	3	0.1475	0.98222	23.33	0.3985
22	3	2	1	3	1	1	0.1358	0.98827	21.72	0.7994
23	3	2	1	3	2	2	0.1576	0.98293	22.58	0.5884
24	3	2	1	3	3	3	0.1662	0.98231	21.78	0.7840
25	3	3	2	1	1	1	0.1116	0.99034	23.02	0.4786
26	3	3	2	1	2	2	0.1514	0.98299	21.84	0.7701
27	3	3	2	1	3	3	0.1976	0.97004	22.26	0.6660


### Analisis Sensitivitas

Dampak variabel yang mempengaruhi kinerja struktural diselidiki dengan melakukan analisis sensitivitas, seperti yang ditunjukkan pada Gambar 7.15. Terlihat bahwa  $G$  dengan skor kepentingan 43.29% dan  $S$  dengan skor kepentingan 27.21% adalah variabel yang paling sensitif untuk output pertama dan kedua, masing-masing.



Dengan demikian, akurasi yang rendah mungkin diperoleh dalam prediksi output ketika pengaruh kedua variabel ini tidak dipertimbangkan.





Sinyal-per-derau: Lebih kecil lebih baik




**Gambar 7.7** Rasio Taguchi untuk: (a) PSO-LSSVM keluaran 1 dan (b) PSO-LSSVM keluaran 2.




**Gambar 7.8** Rasio Taguchi untuk: (a) PIN-SVM keluaran 1 dan (b) PIN-SVM keluaran 2.





**Gambar 7.9** Rasio Taguchi untuk: (a)  $\epsilon$ -TSVM keluaran 1 dan (b)  $\epsilon$ -TSVM keluaran 2.







Gambar 7.10 Rasio Taguchi untuk: (a) WL-ε-TSVM keluaran 1 dan (b) WL-ε-TSVM keluaran 2.







**Gambar 7.11** Plot regresi tegangan maksimum (MPa): (a) ANN, (b) WLSSVM, (c) PSO-LSSVM, (d) PIN-SVM, (e)  $\epsilon$ -TSVM, dan (f) WL- $\epsilon$ -TSVM. (Bersambung)







Gambar 7.11 (Lanjutan)






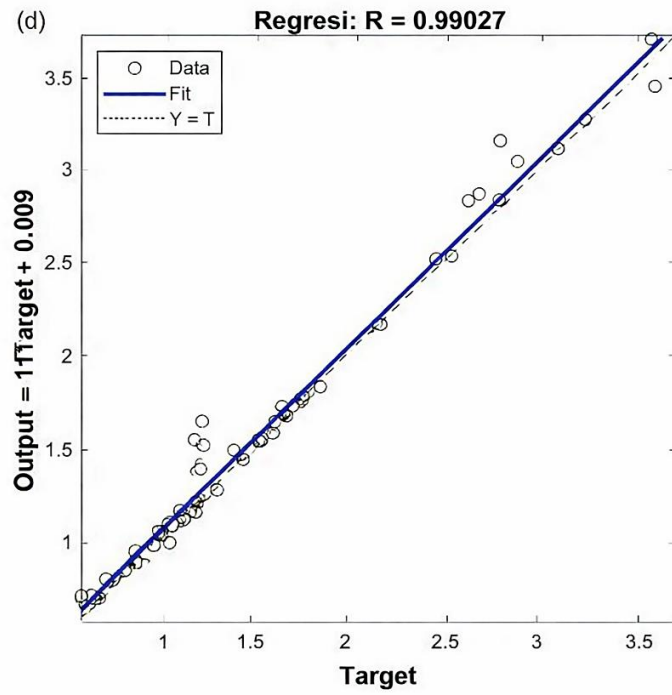
Gambar 7.11 (Lanjutan)



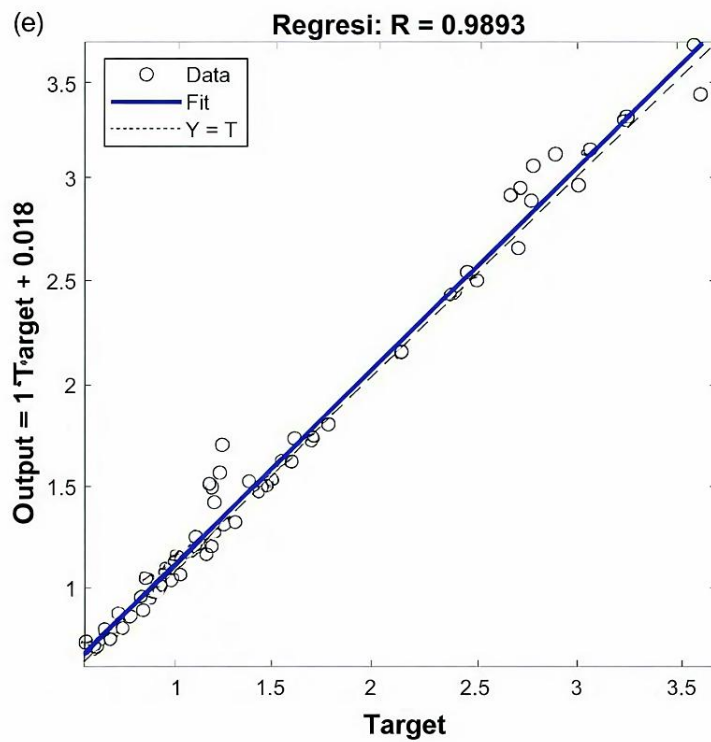


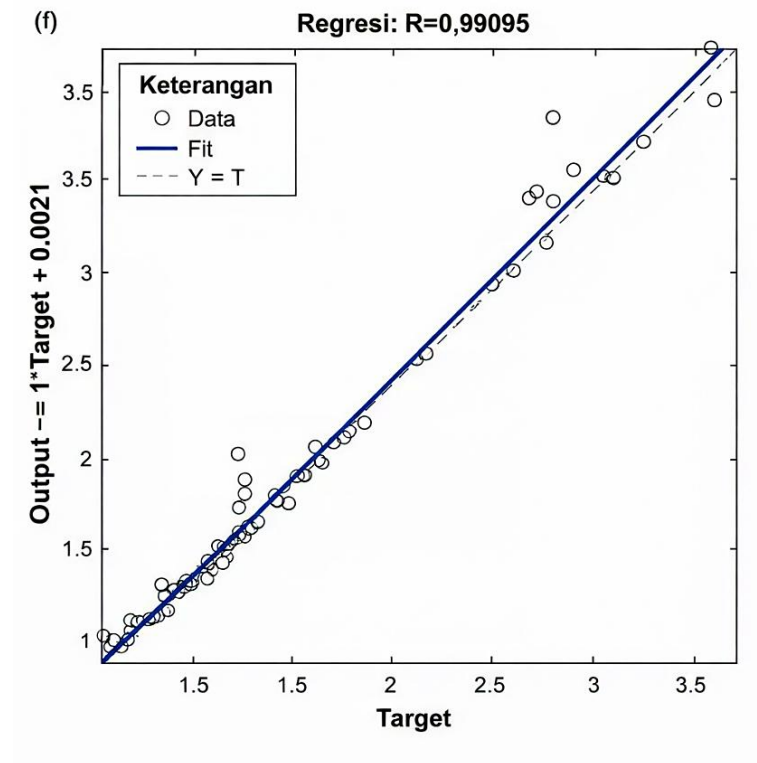
**Gambar 7.12** Plot regresi perpindahan maksimum/berat sendiri (mm/kN): (a) ANN, (b) WLSSVM, (c) PSO-LSSVM, (d) PIN-SVM, (e)  $\epsilon$ -TSVM, dan (f) WL- $\epsilon$ -TSVM. (Bersambung)







Gambar 7.12 (Lanjutan)







Gambar 7.12 (Lanjutan)







**Gambar 7.13** Indeks kinerja algoritma ML: (a) ARD keluaran 1; (b) ARD keluaran 2; (c) NMSE keluaran 1; (d) NMSE keluaran 2; (e) RMSE keluaran 1; (f) RMSE keluaran 2; (g) SD keluaran 1; (h) SD keluaran 2. (Bersambung)







Gambar 7.13 (Lanjutan)





Gambar 7.13 (Lanjutan)

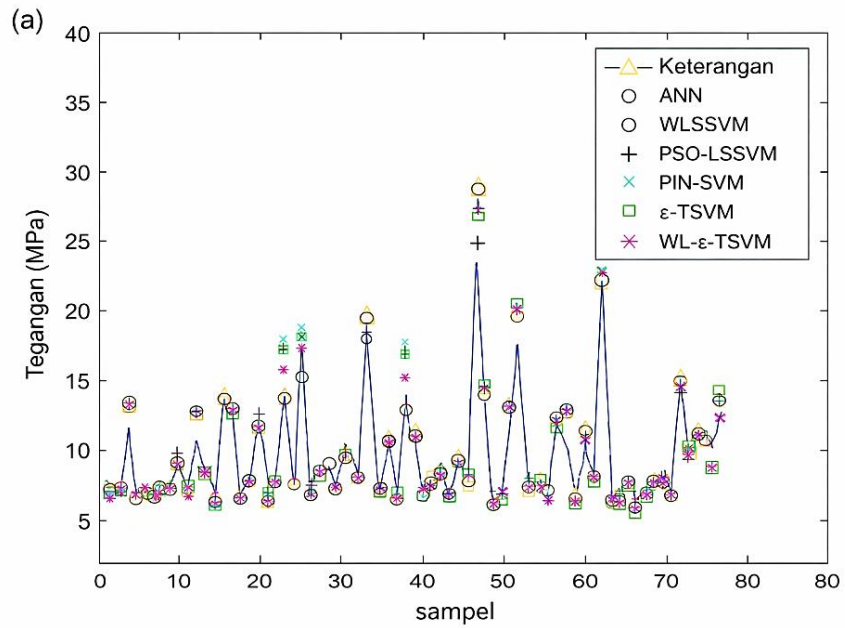





Gambar 7.13 (Lanjutan)

Tabel 7.14 Indikator Kinerja


Model	ARD	NMSE	RMSE	SD	R	Kinerja Prediktif
<b>Tegangan Maksimum (MPa)</b>						
ANN	2.5813	0.0823	1.1024	0.5050	0.96859	0.7222
WLSSVM	1.7347	0.0767	1.0646	0.5095	0.97192	0.8737
PSO-LSSVM	4.9009	0.0748	1.0511	<b>0.4927</b>	0.97239	0.2244
PIN-SVM	2.3330	0.0919	1.1651	0.5304	0.97314	0.6672
$\epsilon$ -TSVM	<b>1.4571</b>	0.0869	1.1330	0.5274	0.97327	0.7639
WLe-TSVM	1.6864	<b>0.0686</b>	<b>1.0069</b>	0.5159	<b>0.97756</b>	<b>0.9691</b>
<b>Perpindahan Maksimum/Berat Sendiri (mm/kN)</b>						
ANN	4.1106	<b>0.0431</b>	<b>0.1640</b>	0.0948	<b>0.97961</b>	<b>0.4479</b>
WLSSVM	2.4199	<b>0.0295</b>	<b>0.1356</b>	0.0955	<b>0.98592</b>	<b>0.9380</b>
PSO-LSSVM	5.1390	<b>0.0272</b>	<b>0.1303</b>	0.0910	<b>0.98800</b>	<b>0.1275</b>
PIN-SVM	2.9322	<b>0.0236</b>	<b>0.1212</b>	0.0972	<b>0.99027</b>	<b>0.8683</b>
$\epsilon$ -TSVM	3.1875	<b>0.0257</b>	<b>0.1266</b>	0.0970	<b>0.98930</b>	<b>0.7919</b>
WLe-TSVM	2.6509	<b>0.0220</b>	<b>0.1172</b>	0.0975	<b>0.99095</b>	<b>0.9439</b>




**Gambar 7.14** Perbandingan nilai sebenarnya dan nilai estimasi data uji oleh algoritma ANN, WLSSVM, PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM: (a) Keluaran 1 dan (b) Keluaran 2. (Bersambung)



**Gambar 7.14** (Lanjutan)



Gambar 7.15 Analisis sensitivitas untuk: (a) output 1 dan (b) output 2.



Gambar 7.15 (Lanjutan)

Pengaruh variabel desain terhadap output dapat dilihat lebih lanjut pada Tabel 7.15. Seperti yang dapat disadari, terdapat perbedaan yang relatif signifikan dalam pengaruh berbagai parameter desain.  $D_2$  dengan skor kepentingan 23.97% untuk output pertama dan  $H_2$  dengan skor kepentingan 23.36% untuk output kedua, menempati peringkat kedua di antara semua variabel yang berpengaruh.  $H_3$  dengan skor kepentingan 2.69%, dan  $G$  dengan skor kepentingan 4.75% memiliki pengaruh minimum pada output pertama dan kedua, masing-masing.

Ditemukan bahwa kedua variabel ini tidak signifikan. Skor kepentingan rata-rata dari variabel yang tersisa, termasuk  $H_1, H_2, H_3, D_1, D_3, S$ , adalah 5.46% untuk output pertama, yang

menyiratkan bahwa parameter-parameter ini memiliki dampak yang relatif kecil pada tegangan maksimum. Oleh karena itu, kumpulan data dapat disiapkan dengan mempertimbangkan variasi signifikan dari  $G$  dan  $S$  untuk meningkatkan akurasi dan mengurangi jumlah sampel dalam observasi selanjutnya.

**Tabel 7.15** Analisis Sensitivitas

Masukan	$Q_m$ (%) untuk $F_1(x)$	$Q_m$ (%) untuk $F_2(x)$
$H_1$	3.77	5.47
$H_2$	6.58	23.36
$H_3$	2.69	14.16
$D_1$	4.42	7.16
$D_2$	23.97	7.53
$D_3$	3.18	10.37
$S$	12.10	27.21
$G$	43.29	4.75

### Proses Optimasi

Empat langkah penting dari prosedur ini adalah sebagai berikut:

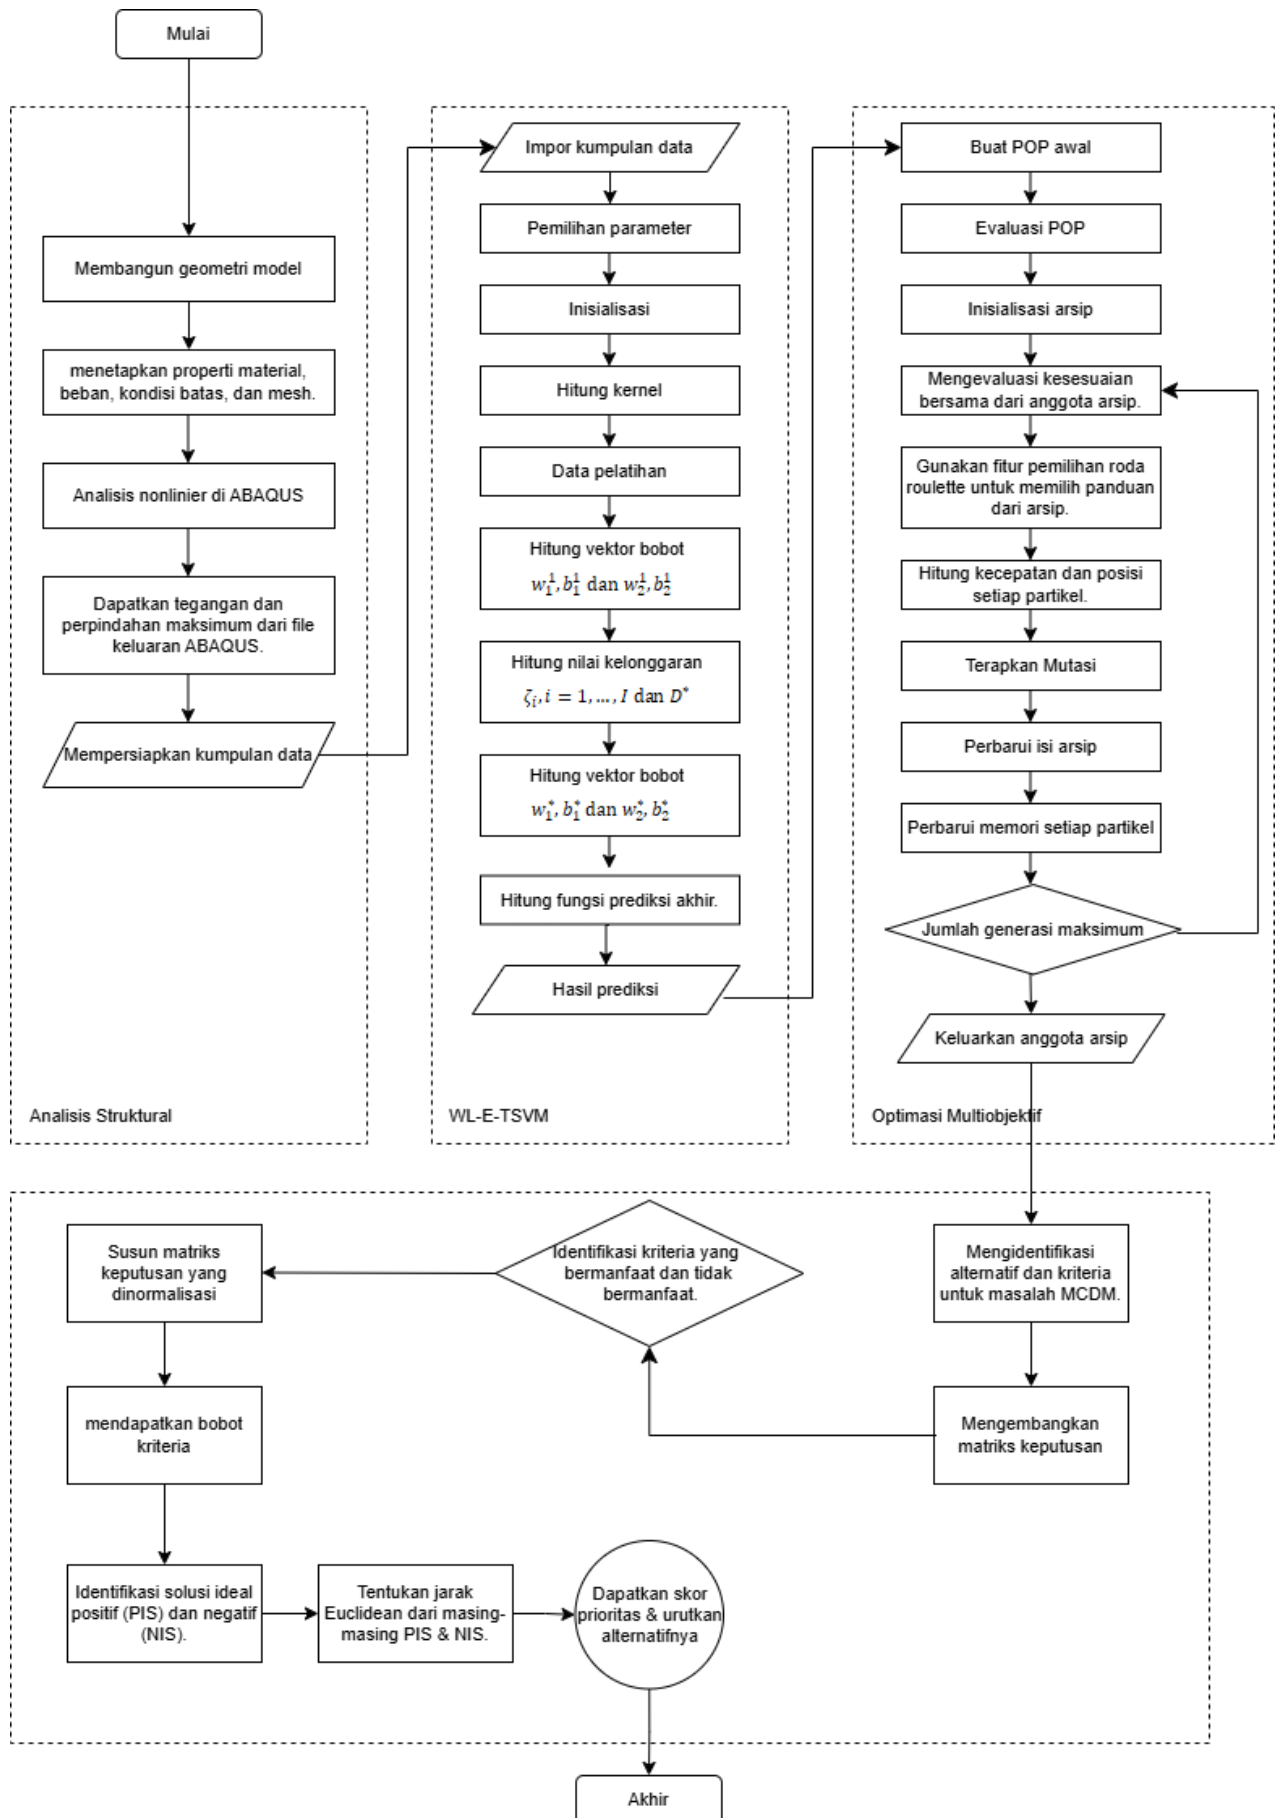
*Langkah 1:* Pemodelan 3D dan analisis sampel;

*Langkah 2:* Memanfaatkan model WL- $\epsilon$ -TSVM;

*Langkah 3:* Memperoleh himpunan Pareto optimal dengan MOPSO;

*Langkah 4:* Mengidentifikasi parameter desain optimal menggunakan metode TOPSIS.

Gambar 7.16 menggambarkan diagram alir dari prosedur ini.



Gambar 7.16 Diagram alir proses optimasi bentuk.

### Masalah Optimasi

Dalam setiap optimasi struktur, variabel harus didefinisikan untuk menemukan solusi optimal. Hal ini menghasilkan deskripsi serangkaian parameter desain. Langkah selanjutnya adalah menentukan tujuan yang harus diikuti dengan menyesuaikan parameter tersebut. Tujuan tersebut didefinisikan dalam bentuk fungsi tujuan. Beberapa kendala harus dipertimbangkan dalam rekayasa struktur. Kondisi seperti biaya produksi dan sifat material harus dipertimbangkan, dan solusi optimal harus memenuhi kriteria ini. Kriteria tersebut ditentukan sebagai serangkaian kendala yang membatasi ruang pencarian ke solusi yang mungkin. Setelah itu, metode optimasi harus dipilih atau ditingkatkan untuk menemukan solusi optimal.

Pendekatan optimasi bentuk yang disajikan bertujuan untuk meningkatkan efisiensi struktural dengan menemukan bentuk optimal struktur sesuai dengan kendala yang dijelaskan. Variabel desain didefinisikan sebagai faktor masukan, dan fungsi kecocokan dianggap sebagai fitur keluaran. Batas bawah dan atas variabel desain diidentifikasi sebagai kondisi kendala untuk prosedur optimasi. Selanjutnya, prosedur optimasi bentuk dilakukan dengan mengimplementasikan MOPSO diikuti dengan pendekatan TOPSIS pada platform MATLAB. Di bidang kecerdasan swarm, algoritma MOPSO diusulkan sebagai salah satu algoritma posterior yang terkenal. Algoritma ini telah disiapkan dengan arsip dan pengontrol arsip untuk menemukan opsi Pareto optimal dari masalah optimasi multi-objektif yang diberikan.

Variabel desain, termasuk tinggi ( $H_1, H_2, H_3$ ), lebar ( $D_1, D_2, D_3$ ), panjang ( $S$ ), dan ukuran grid ( $G$ ), bertindak sebagai parameter desain dalam proses optimasi dan disesuaikan di setiap iterasi. Fungsi objektif juga diperbarui karena menjalankan model WL- $\epsilon$ -TSVM di setiap iterasi oleh platform MATLAB. Algoritma MOPSO bergerak menuju fungsi objektif optimal dengan mengubah nilai fitur input. Kemudian, metode TOPSIS diterapkan di MATLAB dengan menetapkan bobot spesifik untuk setiap fungsi objektif.

Bagian terpenting dari prosedur optimasi adalah mendefinisikan fungsi fitness. Optimasi dalam observasi ini bertujuan untuk meminimalkan dua fungsi objektif. Meminimalkan tegangan di dalam elemen adalah fungsi tujuan pertama. Tegangan terkait dengan kelengkungan anggota dalam gridshell, dan kelengkungan terutama dihasilkan oleh geometri struktur. Kerusakan terjadi pada anggota yang mengalami tegangan berlebih.

**Tabel 7.16** Batas Bawah dan Atas untuk Parameter Desain Gridshell

Parameter	H <sub>1</sub>	H <sub>2</sub>	H <sub>3</sub>	D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	S	G
Batas bawah (m)	4	5	4	14	14	16	32	0.5
Batas atas (m)	8	7	8	18	22	20	37	3

Oleh karena itu, mengendalikan tegangan elemen sangat penting untuk mengatasi masalah ini. Tegangan von Mises ( $\sigma_v$ ) digunakan dalam observasi ini sebagai indeks evaluasi dalam optimasi tegangan. Meminimalkan rasio perpindahan maksimum terhadap berat sendiri

adalah fungsi tujuan kedua. Tabel 7.16 menyajikan batas atas dan bawah untuk variabel desain sebagai kendala selama prosedur optimasi. Oleh karena itu, rentang parameter desain dijelaskan sebagai  $4 \leq H_1, H_2, H_3 \leq 8, 14 \leq D_1 \leq 18, 13 \leq D_2 \leq 22, 16 \leq D_3 \leq 20, 32 \leq S \leq 37$ , dan  $0,5 \leq G \leq 3$ . Dengan bergerak menuju efisiensi struktural yang lebih baik, bentuk yang dioptimalkan ditemukan di antara bentuk-bentuk yang dapat dihasilkan dengan mengubah parameter geometri di dalam rentang yang ditentukan.

**Model Pembelajaran Mesin**

Setiap iterasi proses optimasi memerlukan analisis FE non-linier untuk setiap parameter desain, yang secara signifikan meningkatkan waktu komputasi. Akibatnya, WL- $\epsilon$ -TSVM digunakan dalam program MATLAB daripada analisis FE untuk memprediksi kinerja struktural guna mengurangi waktu yang dibutuhkan untuk memperoleh hasil analisis. Sebuah dataset yang terdiri dari 360 sampel yang dihasilkan disiapkan. Algoritma ML kemudian diterapkan menggunakan teknik K-fold CV. Untuk menghilangkan keacakan intrinsik dalam memilih sampel pelatihan dan pengujian, prosedur CV sepuluh kali lipat diterapkan di MATLAB. Sebagai hasil dari proses CV sepuluh kali lipat, hasilnya akan menjadi semakin andal. Seluruh basis data dibagi secara rata-rata dan acak menjadi 10 subset data, dengan setiap subset berfungsi sebagai set pengujian dan sembilan lipatan sisanya bertindak sebagai set pelatihan.

**Penyetelan Parameter MOPSO**

Tabel 7.17 menyajikan tingkat dan rentang parameter yang digunakan untuk mengoptimalkan algoritma MOPSO dengan metode Taguchi yang dilakukan di Minitab. Nilai untuk setiap parameter didefinisikan berdasarkan tiga tingkat. Tabel 7.18 menampilkan array ortogonal dan hasil terkaitnya. Pengaruh setiap variabel pada rasio S/N digambarkan pada Gambar 7.17. Hasilnya, masalah MOPSO diterapkan menggunakan  $C_1 = 2, C_2 = 1, W = 0.6, PS = 100, NOI = 200$ , dan ukuran repositori 50.

**Tabel 7.17** Rentang dan Tingkat Parameter MOPSO

Parameter	Rentang	Rendah (1)	Sedang (2)	Tinggi (3)
C <sub>1</sub>	1.0 – 2.0	1.0	1.5	2.0
C <sub>2</sub>	1.0 – 2.0	1.0	1.5	2.0
W	0.4 – 0.9	0.4	0.6	0.9
PS	50 – 100	50	75	100
NOI	100 – 200	100	150	200

**Hasil MOPSO**

Menggunakan pendekatan optimasi yang direkomendasikan, nilai optimal untuk variabel desain dan fungsi fitness ditetapkan secara bersamaan oleh algoritma MOPSO.

**Tabel 7.18** Proses Kalibrasi MOPSO


Urutan Percobaan	Parameter Algoritma					Respon
	C <sub>1</sub>	C <sub>2</sub>	W	PS	NOI	
1	1	1	1	1	1	0.002099154

Urutan Percobaan	Parameter Algoritma					Respon
	C <sub>1</sub>	C <sub>2</sub>	W	PS	NOI	
2	1	1	1	1	2	0.000443727
3	1	1	1	1	3	0.001398018
4	1	2	2	2	1	0.002198554
5	1	2	2	2	2	0.000966134
6	1	2	2	2	3	0.001556423
7	1	3	3	3	1	0.000872894
8	1	3	3	3	2	0.001111961
9	1	3	3	3	3	0.000992087
10	2	1	2	3	1	0.002507426
11	2	1	2	3	2	0.001309393
12	2	1	2	3	3	0.002678544
13	2	2	3	1	1	0.000920174
14	2	2	3	1	2	0.001039192
15	2	2	3	1	3	0.000959193
16	2	2	1	2	1	0.000787839
17	2	3	1	2	2	0.00056153
18	2	3	1	2	3	0.001359227
19	3	1	3	2	1	0.001359227
20	3	1	3	2	2	0.000819904
21	3	1	3	2	3	0.002348855
22	3	2	1	3	1	0.001162563
23	3	2	1	3	2	0.001591835
24	3	2	1	3	3	0.001127225
25	3	3	2	1	1	0.000565923
26	3	3	2	1	2	0.002053324
27	3	3	2	1	3	0.001946524


Metode TOPSIS diimplementasikan dalam MATLAB untuk memberi peringkat 50 opsi optimum Pareto guna menentukan gridshell dengan kinerja struktural tertinggi. Front Pareto yang dihasilkan oleh MOPSO dan opsi terbaik yang diperoleh oleh TOPSIS ditampilkan pada Gambar 7.18. Gambar 7.19 mengilustrasikan perbandingan nilai prediksi dan aktual dari front Pareto, yang menunjukkan akurasi model prediksi. Nilai NMSE, RMSE, dan *R* masing-masing adalah 0.0577, 0.2839, dan 0.9712 untuk fungsi tujuan pertama, sedangkan untuk fungsi tujuan kedua masing-masing adalah 0.0401, 0.0079, dan 0.9812. Sebagai hasilnya, Tabel 7.19 menunjukkan parameter desain optimum yang dicapai oleh pendekatan WL $\epsilon$ T SVM-MOPSO-TOPSIS untuk meningkatkan perilaku struktural.

Tabel 7.20 menyajikan perbandingan hasil simulasi yang diperoleh dengan FEA dan hasil yang diperoleh dengan teknik hibrida yang diusulkan. Ditemukan bahwa nilai yang diberikan oleh pendekatan hibrida yang diusulkan dan nilai yang dihitung menggunakan FEA

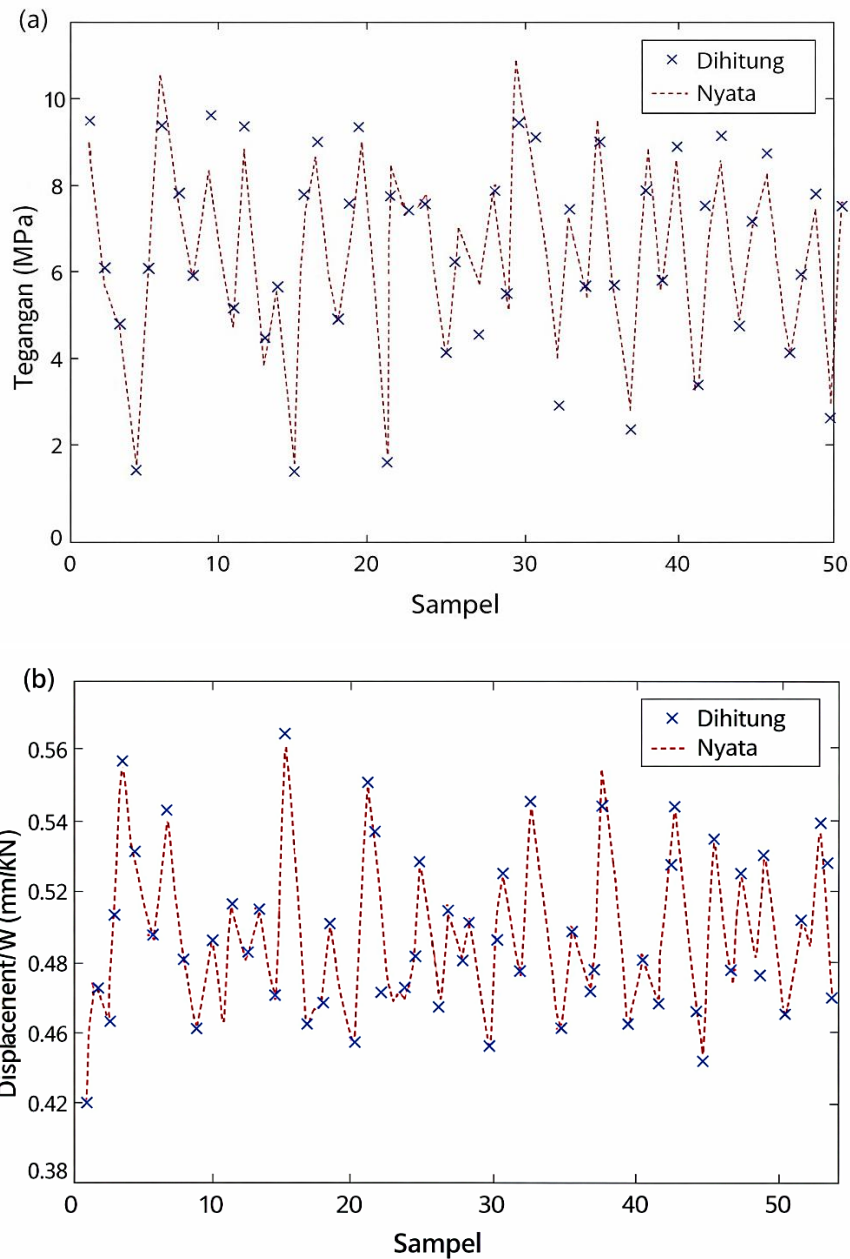
hanya berbeda sebesar 2%. Akibatnya, metode hibrida WL $\epsilon$ TSVM-MOPSO-TOPSIS mengurangi waktu, dan mampu menentukan bentuk struktur yang optimal sebagai metode yang efektif dan efisien.



Gambar 7.17 Rasio Taguchi untuk MOPSO.



Gambar 7.18 Pareto front dan titik optimal Pareto yang diperoleh oleh MOPSO\_TOPSIS.



**Gambar 7.19** Perbandingan nilai sebenarnya dan nilai estimasi dari Pareto front: (a) fungsi tujuan 1 dan (b) fungsi tujuan 2.

**Tabel 7.19** Nilai Optimum Parameter Desain

$H_1$	$H_2$	$H_3$	$D_1$	$D_2$	$D_3$	$S$	$C$	Fungsi Objektif 1	Fungsi Objektif 2
7	2	2	2	2	3	35	2.4	4.39	0.439

**Tabel 7.20** Perbandingan Fungsi Tujuan 1 dan 2 untuk Gridshell yang Dioptimalkan yang Diperoleh dengan FEA dan WL- $\epsilon$ -TSVM

Fungsi Objektif	FEA	WL- $\epsilon$ -TSVM	Galat	Galat Relatif
Fungsi Objektif 1	4.51	4.39	0.12	2.66%
Fungsi Objektif 2	0.54	0.55	0.01	1.82%

### **Evaluasi Bentuk Optimal**

Untuk membuktikan efisiensi proses hibrida yang ditawarkan dalam meningkatkan kinerja struktur, kinerja bentuk yang dioptimalkan dan dua struktur lain yang memiliki fungsi fitness maksimum dievaluasi. Investigasi selanjutnya dari analisis struktural diperoleh menggunakan FEA. Perlu disebutkan bahwa berat penguat tidak memiliki dampak yang signifikan pada perilaku struktural karena kepadatan material GFRP yang rendah; oleh karena itu, dalam observasi ini, berat sendiri penguat tidak dipertimbangkan.

Menurut fungsi tujuan, ada tiga kasus struktural yaitu sebagai berikut:

*Kasus 1:* Dengan fungsi tujuan optimal;


*Kasus 2:* Dengan fungsi tujuan maksimum 1;

*Kasus 3:* Dengan fungsi tujuan maksimum 2.


Struktur dari ketiga kasus tersebut mencakup area sekitar 521 m<sup>2</sup>, 506 m<sup>2</sup>, dan 508 m<sup>2</sup>, dengan berat masing-masing 6.10 kN, 23.93 kN, dan 7.05 kN. Gambar 7.20 dan 7.21 mengilustrasikan distribusi tegangan dan perpindahan dari masing-masing kasus. Selain itu, nilai maksimumnya juga ditampilkan.

Tegangan maksimum pada Kasus 1 dan Kasus 2 masing-masing adalah 4.51 MPa dan 30.17 MPa; akibatnya, tegangan struktural maksimum telah meningkat hampir 85% sebagai hasil optimasi. Lebih lanjut, rasio perpindahan maksimum terhadap berat sendiri adalah 0.54 mm/kN pada Kasus 1 dan 10.62 mm/kN pada Kasus 3; akibatnya, kinerja yang lebih tinggi hampir 95% ditentukan dalam hal efisiensi struktural. Kesimpulannya, pendekatan optimasi yang disarankan mampu meningkatkan kinerja struktural karena nilai fungsi objektif berkurang secara signifikan. Untuk menyelidiki efektivitas prosedur secara ekstensif, kinerja struktural, termasuk tegangan semua elemen dan perpindahan semua simpul, diekstrak untuk perbandingan. Untuk tujuan ini, tiga kasus yang disebutkan dianalisis, dan hasilnya diperoleh. Gambar 7.22 dan 7.23 menampilkan perbandingan tegangan pada Kasus 1 dan Kasus 2 dan rasio perpindahan terhadap berat sendiri pada Kasus 1 dan Kasus 3, masing-masing.

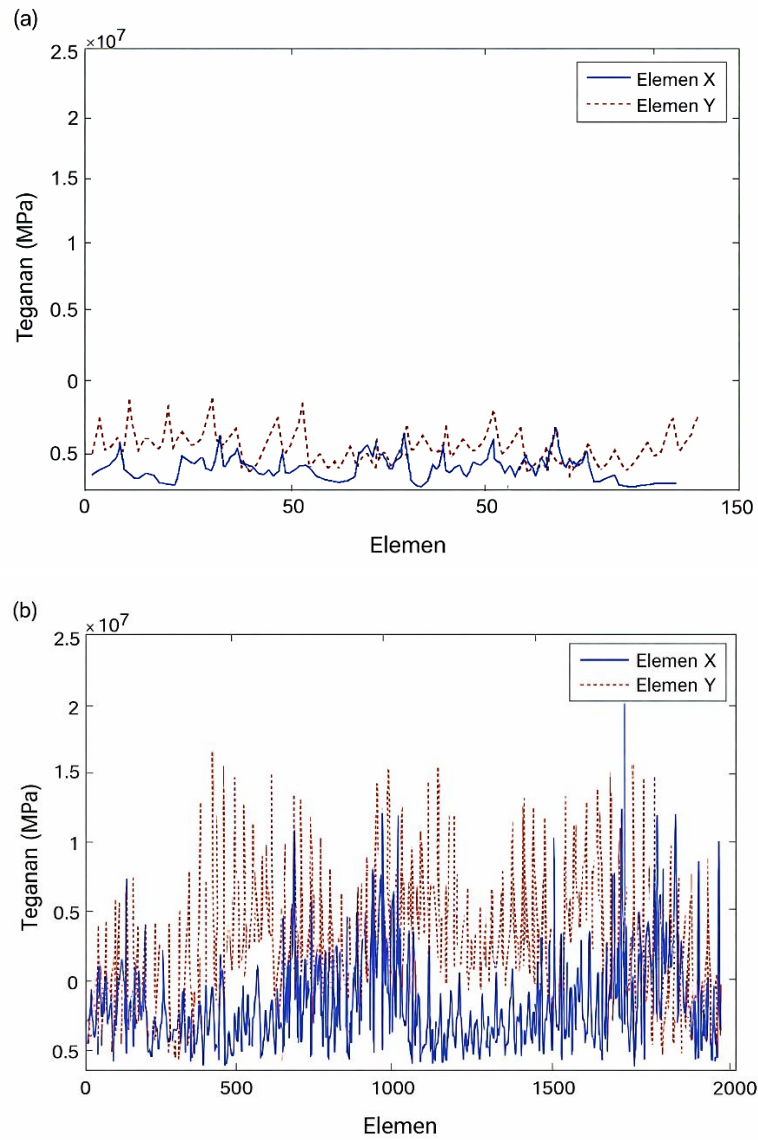
Gambar 7.22 menunjukkan bahwa tegangan pada bentuk yang dioptimalkan biasanya lebih rendah daripada pada Kasus 2. Karena tegangan pada gridshell berkurang, prosedur optimasi menghasilkan penurunan kerusakan struktural yang cukup besar, dan gridshell optimal dapat menahan kegagalan yang disebabkan oleh kerusakan elemen. Dalam hal rasio perpindahan terhadap berat sendiri, struktur yang dioptimalkan menunjukkan mitigasi yang signifikan dibandingkan dengan Kasus 3, seperti yang diilustrasikan pada Gambar 7.23. Akibatnya, jelas bahwa kinerja struktural keseluruhan dari struktur dengan bentuk optimal meningkat secara signifikan, yang menegaskan efisiensi teknik optimasi bentuk hibrida yang disarankan.




**Gambar 7.20** (a)  $H1 = 7, H2 = 7, H3 = 5, D1 = 15, D2 = 19, D3 = 18, S = 35, G = 2,4$ ; tegangan maksimum = 4,51 MPa. (b)  $H1 = 7, H2 = 5, H3 = 5, D1 = 16, D2 = 15, D3 = 18, S = 35, G = 0,6$ ; tegangan maksimum = 30,17 MPa. Distribusi tegangan struktur cangkang kisi: (a) Kasus 1 dan (b) Kasus 2.




**Gambar 7.21** (a)  $H1 = 7, H2 = 7, H3 = 5, D1 = 15, D2 = 19, D3 = 18, S = 35, G = 2,4$ ; perpindahan maksimum/berat sendiri = 0,54 mm/kN. (b)  $H1 = 7, H2 = 6, H3 = 5, D1 = 15, D2 = 16, D3 = 18, S = 36, G = 2$ ; perpindahan maksimum/berat sendiri = 10,62 mm/kN. Distribusi perpindahan arah z dari struktur cangkang kisi: (a) Kasus 1 dan (b) Kasus 3.



Gambar 7.22 Perbandingan tegangan antara dua kasus: (a) Kasus 1 dan (b) Kasus 2.





**Gambar 7.23** Perbandingan perpindahan/berat sendiri antara dua kasus: (a) Kasus 1 dan (b) Kasus 3.

#### **7.5 PERBANDINGAN MODEL ML DAN OPTIMASI BENTUK GRIDSHHELL GFRP**

Bab ini menyajikan studi perbandingan model ML, termasuk ANN, WLSSVM, PSO-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM untuk prediksi kinerja struktural. K-fold CV, TOPSIS, dan pendekatan Taguchi diimplementasikan untuk menyetel parameter algoritma ini. Hasil prediksi dibandingkan berdasarkan indikator kinerja ARD, NMSE, RMSE, SD, dan R. Selanjutnya, metode TOPSIS diterapkan untuk mengidentifikasi model yang paling diinginkan. Parameter input meliputi tiga faktor tinggi, tiga faktor lebar, panjang, dan ukuran grid, sedangkan variabel output adalah tegangan maksimum sebagai output pertama dan rasio perpindahan maksimum terhadap berat sendiri sebagai output kedua. Kelayakan enam algoritma ML untuk prediksi analisis struktural dinilai. Hasilnya menunjukkan bahwa algoritma ML menunjukkan potensi besar untuk prediksi analisis struktural. Nilai R dari algoritma pada set pengujian berkisar dari 0.96859 (ANN) dan 0.97756 (WL- $\epsilon$ -TSVM) untuk output pertama dan dari 0.97961 (ANN) hingga 0.99095 (WL- $\epsilon$ -TSVM) untuk output kedua.

Nilai kinerja prediksi tertinggi dicapai oleh algoritma WL- $\epsilon$ -TSVM (0.9691), diikuti oleh algoritma WLSSVM (0.8737) untuk output pertama, dan oleh algoritma WL- $\epsilon$ -TSVM (0.9439) dan algoritma WLSSVM (0.9380) untuk output kedua. Oleh karena itu, model WL- $\epsilon$ -TSVM direkomendasikan untuk prediksi kinerja struktural karena akurasi yang relatif tinggi. Pengaruh variabel desain terhadap perilaku struktural dinilai melalui analisis sensitivitas, di mana ukuran grid ( $G$ ) dan panjang sepanjang arah  $y$  ( $S$ ) diidentifikasi sebagai variabel yang paling signifikan untuk keluaran pertama dan kedua, masing-masing.

Dalam proses desain struktur tersebut, menentukan bentuk struktural yang dapat diterima sambil mempertimbangkan perilaku struktural merupakan tugas yang sangat penting. Tujuan bab ini adalah untuk mengusulkan pendekatan optimasi bentuk untuk gridshell elastis GFRP yang memperhitungkan berat struktural, dengan tujuan meminimalkan tegangan dan deformasi struktural. Untuk tujuan ini, metode hibrida baru, yang disebut

WLETSVM-MOPSO-TOPSIS, disajikan. Algoritma MOPSO diimplementasikan untuk menentukan bentuk gridshell optimal berdasarkan perilaku struktural yang diperkirakan, sementara pendekatan Taguchi digunakan untuk menyesuaikan variabelnya. Metode TOPSIS kemudian diterapkan pada himpunan optimal Pareto untuk mengidentifikasi opsi terbaik. Pendekatan yang diusulkan dinilai dengan contoh numerik, dan kinerja struktural gridshell yang dioptimalkan dievaluasi dengan FEA. Hasil observasi menunjukkan bahwa teknik yang direkomendasikan dapat mengidentifikasi bentuk struktur yang optimal dengan kinerja struktural yang sangat baik.



## BAB 8

# KESIMPULAN DAN REKOMENDASI DESAIN DAN OPTIMASI GRIDSHELL

### 8.1 APLIKASI ML UNTUK DESAIN DAN OPTIMASI GRIDSHELL GFRP

Dalam kasus struktur gridshell elastis polimer yang diperkuat serat kaca (GFRP), metode tradisional seringkali terbukti rumit dan memakan waktu untuk menyelesaikan berbagai masalah desain dan kinerja. Model baru telah dikembangkan untuk meningkatkan efisiensi dan kinerja struktur gridshell untuk mengatasi tantangan ini. Buku ini mengeksplorasi penerapan kecerdasan buatan (AI) dan pembelajaran mesin (ML) sebagai teknik komputasi lunak praktis di bidang ini. Observasi ini mengevaluasi efektivitas ML di bidang-bidang seperti prediksi bentuk, pencarian bentuk, penilaian kinerja struktural, dan optimasi bentuk struktur gridshell. Lebih lanjut, prospek implementasi ML dan pola pengembangan dianalisis berdasarkan temuan observasi.

Hasil dari kerangka kerja berbasis ML ini dibandingkan dengan analisis elemen hingga (FEA), yang mengkonfirmasi efisiensi model yang diusulkan. Selain itu, mengintegrasikan BIM dengan strategi optimasi dalam proses desain memungkinkan peningkatan manajemen data dan kolaborasi waktu nyata, yang selanjutnya menyederhanakan optimasi bentuk gridshell dan kinerja struktural. Akibatnya, validitas dan efektivitas pendekatan ML untuk meningkatkan desain dan kinerja gridshell elastis diverifikasi, yang mengarah pada beberapa kesimpulan penting sebagai berikut:

1. Metode analitik diperkenalkan untuk memperkirakan deformasi dan momen lentur balok kantilever selama proses pengangkatan dan pemasangan, berdasarkan teori elemen diskrit yang dikenai gaya terpusat ke bawah dan berat sendiri. Pendekatan analitik yang diusulkan divalidasi efisiensi dan akurasi melalui FEA. Selain itu, metode ML disajikan untuk memprediksi bentuk batang ramping selama proses pengangkatan, juga menggunakan model elemen diskrit. Tiga algoritma ML, yaitu *parametric-insensitive nonparallel-support vector machine* (PIN-SVM),  *$\epsilon$ -twin support vector machine* ( $\epsilon$ -TSVM), dan WL- $\epsilon$ -TSVM, dibandingkan. WL- $\epsilon$ -TSVM menunjukkan kinerja yang lebih unggul dan karenanya diterapkan pada balok kantilever dengan deformasi geometris yang besar. Akurasi dan kelayakan pendekatan berbasis ML ini dikonfirmasi menggunakan FEA. Lebih lanjut, metode ML diperluas untuk memprediksi bentuk struktur gridshell elastis GFRP selama pemasangan, menggunakan model elemen diskrit. Kebaruan metode ini terletak pada pemanfaatan karakteristik elemen diskrit untuk membuat dataset alih-alih mengandalkan FEA yang intensif secara komputasi. Pendekatan ini menggabungkan WL- $\epsilon$ -TSVM, validasi silang sepuluh kali lipat (CV), teknik untuk preferensi urutan berdasarkan kesamaan dengan solusi ideal (TOPSIS), dan metode Taguchi. Hasil observasi menunjukkan bahwa metode yang diusulkan secara efektif memprediksi bentuk deformasi dan momen lentur struktur

- cangkang jaring di bawah beban berat sendiri dan beban terpusat ke bawah, dengan memperhitungkan deformasi geometris yang signifikan selama proses pengangkatan.
2. Sebuah metode pencarian bentuk baru untuk struktur cangkang jaring elastis GFRP yang mengalami deformasi sendiri dikembangkan menggunakan pendekatan ML yang dapat diinterpretasikan. Di antara berbagai model ML, termasuk SVM, *K-nearest neighbor* (KNN), *decision tree* (DT), *random forest* (RF), AdaBoost, XGBoost, CatBoost, dan LightGBM, LightGBM menunjukkan akurasi tertinggi dan karenanya dipilih untuk analisis yang dapat diinterpretasikan. Teknik ML yang dapat diinterpretasikan seperti *partial dependence plot* (PDP), *accumulated local effects* (ALE), dan SHAP digunakan untuk menentukan nilai optimal untuk setiap variabel guna meminimalkan fungsi tujuan. Akibatnya, konfigurasi kisi datar optimal untuk kisi elastis diperoleh. Perbandingan antara kasus dengan fungsi tujuan minimum dan maksimum lebih lanjut memvalidasi metode yang diusulkan. Metode ini menunjukkan presisi tinggi dalam pencarian bentuk untuk struktur cangkang jaring, khususnya berkaitan dengan proses pengangkatan dan pemasangan. Simulasi proses konstruksi dilakukan, di mana perpindahan yang ditentukan diterapkan pada titik pengangkatan untuk mensimulasikan prosedur pengangkatan. Analisis distribusi tegangan mengungkapkan konsentrasi tegangan pada simpul pengangkatan yang disebabkan oleh kabel penghubung, yang memerlukan perhatian cermat selama prosedur konstruksi.
  3. Teknik regresi ML telah dikembangkan untuk memprediksi kinerja struktural cangkang grid elastis di bawah berat sendiri. Di antara model yang dievaluasi, CatBoost menunjukkan akurasi tertinggi, mencapai nilai  $R^2$  tertinggi dan nilai RMSE terendah, mengungguli model seperti regresi linier (LR), regresi ridge (RR), SVM, KNN, DT, RF, AdaBoost, XGBoost, CatBoost, dan LightGBM. Sebaliknya, model LR dan RR menunjukkan akurasi terendah, dengan nilai  $R^2$  terendah dan nilai RMSE tertinggi. Akibatnya, CatBoost dipilih untuk analisis interpretasi. Metode ML yang dapat diinterpretasikan, termasuk PDP, ALE, dan SHAP, digunakan untuk memberi peringkat fitur input dan menjelaskan tren dalam prediksi. Penting untuk dicatat bahwa tidak ada satu metode pun yang cukup untuk semua kebutuhan interpretasi. SHAP efektif dalam menjelaskan model prediksi dan mengidentifikasi pentingnya parameter input, tetapi tidak dapat mengatasi ambang batas estimasi atau bagaimana modifikasi input memengaruhi prediksi. PDP dan ALE dapat mengatasi keterbatasan ini, dengan ALE menawarkan alternatif yang lebih cepat dan tidak bias dibandingkan PDP. Oleh karena itu, PDP, ALE, dan SHAP bersama-sama menyediakan kerangka kerja komprehensif untuk menginterpretasikan model ML.
  4. Analisis komparatif diusulkan untuk mengidentifikasi algoritma yang paling tepat untuk mengoptimalkan cangkang grid elastis GFRP. Enam pendekatan ML, termasuk jaringan saraf tiruan (ANN), SVM kuadrat terkecil berbobot (WLSSVM), optimasi swarm partikel (PSO)-LSSVM, PIN-SVM,  $\epsilon$ -TSVM, dan WL- $\epsilon$ -TSVM, dievaluasi dan dibandingkan untuk prediksi analisis struktural. Kinerja prediksi tertinggi dicapai oleh algoritma WL- $\epsilon$ -TSVM, diikuti oleh algoritma WLSSVM. Oleh karena itu, algoritma WL- $\epsilon$ -TSVM dianggap

sebagai model paling sukses untuk prediksi kinerja struktural berdasarkan indikator kinerja. Pentingnya relatif variabel desain diselidiki melalui analisis sensitivitas, dengan ukuran grid dan bentang diidentifikasi sebagai variabel yang paling signifikan. Teknik optimasi bentuk baru disajikan untuk struktur gridshell yang dikenai beban struktural, yang dikenal sebagai teknik hibrida WL- $\epsilon$ -TSVM-MOPSO-TOPSIS. Model WL- $\epsilon$ -TSVM digunakan untuk memprediksi perilaku struktural dan menghilangkan analisis elemen hingga (FEA) yang memakan waktu menggunakan validasi silang 10-fold. Model MOPSO kemudian digunakan dalam proses optimasi untuk menentukan geometri optimal struktur. Metode Taguchi diterapkan secara efektif untuk menyempurnakan variabel MOPSO. Akhirnya, metode TOPSIS berhasil digunakan untuk mengidentifikasi hasil Pareto front yang optimal. Kesimpulannya, struktur yang dioptimalkan menunjukkan peningkatan signifikan dalam perilaku struktural, menunjukkan bahwa teknik optimasi hibrida yang diusulkan efektif untuk optimasi struktural struktur gridshell.

## **8.2 REKOMENDASI OBSERVASI MASA DEPAN**

Berdasarkan kesimpulan dan hasil observasi ini, berikut adalah rekomendasi untuk observasi selanjutnya:

1. Dalam observasi selanjutnya, penggunaan metode hibrida yang dapat mencapai akurasi lebih tinggi sangat penting. Pengembangan sistem cerdas generasi berikutnya memiliki potensi signifikan karena hibridisasi metode ML. Hibridisasi meningkatkan metode asli dengan mengatasi keterbatasan teknik individual. Oleh karena itu, disarankan untuk mengembangkan model yang tangguh berdasarkan pendekatan hibrida.
2. Untuk pekerjaan selanjutnya, kumpulan data gridshell yang lebih luas yang dikenai beban lingkungan kompleks harus dikumpulkan untuk meningkatkan ketahanan. Hal ini akan memungkinkan algoritma ML untuk diterapkan secara lebih luas dan efektif.
3. Arah potensial lainnya adalah mempertimbangkan pengaruh variabel saat menyiapkan kumpulan data. Studi tentang korelasi internal antar variabel dapat dilakukan. Selanjutnya, kinerja prediksi dapat ditingkatkan melalui pemilihan fitur dan pra-pemrosesan data.
4. Disarankan untuk menggunakan model perekaman universal untuk struktur gridshell. Hal ini sangat penting untuk menciptakan kumpulan data yang konsisten dan serangkaian sampel yang seragam. Akibatnya, kumpulan data sumber terbuka yang andal dapat tersedia bagi para insinyur dan peneliti di seluruh dunia untuk studi masa depan tentang struktur cangkang kisi.
5. Meskipun kesimpulan yang diambil dari studi ini didasarkan pada struktur cangkang kisi, metode yang digunakan dalam studi ini dapat diterapkan pada jenis struktur lain dalam observasi di masa mendatang. Metode ini dapat diimplementasikan untuk struktur yang terbuat dari balok, menawarkan manfaat peningkatan kinerja struktural sekaligus meminimalkan waktu komputasi.

## DAFTAR PUSTAKA

- Bodea, S. (2023). *Upscaled, robotic coreless filament winding methods for lightweight building elements for architecture*. Institute for Computational Design and Construction, University of Stuttgart.
- Bruscia, N., Kanaoka, D., & Fujiwara, T. Deployable and Reusable Pop-Up Bamboo Gridshell Traditionally Fabricated in Mixed Reality.
- Charest, P. Vers une architecture biophilique: Matérialisation de la complexité formelle au moyen de structures en résille de bois Thèse.
- Cui, Z., Zhang, S., Viscuso, S., & Zanelli, A. (2023). Weaving octopus: An assembly–disassembly-adaptable customized textile hybrid prototype. *Buildings*, 13(10), 2413.
- Darweesh, B. A. (2024). *Adaptive Frameworks for Robotic Non-Planar Additive Manufacturing* (Doctoral dissertation, University of California, Berkeley).
- Fan, S. L., Huang, K. C., Wu, C. T., Kookalani, S., Brilakis, I., Recha, F., & Walusiak, Ł. Research on the Integration and Enhancement of Artificial Intelligence and Augmented Reality in Construction Progress Management. *Available at SSRN 5460397*.
- Fard, M. S., Ghaderi, E., & Pourfouladi, M. (2025). Free-form grid structure multi-objective optimization associated with integrated design and machine learning. *Engineering Structures*, 329, 119827.
- Fernandes, M. J. G. (2019). *Elastic Timber Gridshells. From the Finding form Process to the Erection of Efficient Lightweight Structures* (Doctoral dissertation, Universidade do Minho (Portugal)).
- Gokmen, S. (2023). Stripped and layered fabrication of minimal surface tectonics using parametric algorithms. *Curved and Layered Structures*, 10(1), 20220210.
- Gonçalves, V. S. F., & de Carvalho, V. R. (2025). A review of interpretability methods for gradient boosting decision trees. *Journal of the Brazilian Computer Society*, 31(1), 639–653.
- Hu, J., Bai, J., Huang, W., & Chen, Y. (2025, July). “Infinity Pavilion”: Design and Construction of a Segment-Assembling GFRP Elastic Weaving Gridshell. In *International Conference on Fibre-Reinforced Polymer (FRP) Composites in Civil Engineering* (pp. 1876-1884). Cham: Springer Nature Switzerland.

- Kookalani, S., Nyunn, S., & Xiang, S. (2022). Form-finding of lifting self-forming GFRP elastic gridshells based on machine learning interpretability methods. *Structural Engineering and Mechanics*, 84(5), 605-618.
- La Magna, R. Universität Stuttgart-Institut für Tragkonstruktionen und Konstruktives Entwerfen  
Herausgeber: Professor Dr.-Ing. Jan Knippers Forschungsberichte itke 43 itk.
- Li, S., Zhang, Y., Mi, X., Huang, X., & Chen, W. (2023). Design and integrated tension test of a large-scale modular CFRP wheel-spoke-shaped structure. *Engineering Structures*, 275, 115238.
- McLean, W., & Silver, P. (2021). *Environmental Design Sourcebook: Innovative Ideas for a Sustainable Built Environment*. Routledge.
- Meng, Y. (2023). *Multi-objective optimal design and assessment framework of freeform timber structure oriented by robotic automation construction* (Doctoral dissertation, University of Sheffield).
- Menges, A., & Knippers, J. (2020). *Architecture Research Building: ICD/ITKE 2010-2020*. Birkhäuser.
- Shu, P., Xue, C., Zhang, G., & Deng, T. (2024). Study on design optimization of GFRP tubular column composite structure based on machine learning method. *Plos one*, 19(4), e0301865.
- Sivashanmugam, S., Trejo, S. R., & Rahimian, F. P. (2025). *Enhancing Interoperability and Automation of Construction Waste Quantification: Integration of Building Information Modelling and Semantic Web Technology*. Taylor & Francis.
- Stonorov, T. (2023). Compression: Fabric Formed Concrete and Dense Applications. In *FABRIC [ated]* (pp. 144-195). Routledge.
- Svilans, T. (2020). *Integrated material practice in free-form timber structures* (Doctoral dissertation, The Royal Danish Academy of Fine Arts, Schools of Architecture, Design and Conservation).
- Tamke, M. (2020). Integrated Material Practice in Freeform Timber Structures. *Design Transactions*.
- Tong, R. K. L. (2024). *Hybrid Explorations Through Handcrafts and Computational Processes* (Doctoral dissertation, Carleton University).
- Wagiri, F., Shih, S. G., Wijaya, D. C., Stavric, M., & Harsono, K. (2025). Integration of Fabric Formwork and Geodesic Grids for Hemispherical Dome Fabrication. *Nexus Network Journal*, 27(4), 849-874.

- Wang, M., Du, M., Zhuang, X., Lv, H., Wang, C., & Zhou, S. (2025). Multi-objective optimization of ultra-high performance concrete based on life-cycle assessment and machine learning methods. *Frontiers of Structural and Civil Engineering*, 19(1), 143-161.
- Xia, Z. Y., Jiang, T., & Yu, T. (2023). Innovating arch structures with fiber-reinforced polymer composites: A review. *Advances in Structural Engineering*, 26(13), 2341-2358.
- Xiang, S., Cheng, B., & Kookalani, S. (2020). An analytic solution for form finding of GFRP elastic gridshells during lifting construction. *Composite Structures*, 244, 112290.
- Yavaribajestani, Y. (2023). *Design, Fabrication and Analysis of Bending-Active Hybrid Gridshells* (Doctoral dissertation, University of California, Berkeley).
- Zanelli, A., Kolo, E., Monticelli, C., Rosina, E., Poli, T., Speroni, A., & Mainini, A. G. (2019). A tensile screen for the windows of Castello Sforzesco: integrating anemometric, optical and mechanical tests in the early-stage design of bespoke textile hybrid structures in historical contexts. In *SOFTENING THE HABITATS-Sustainable innovation in minimal mass structures and lightweight architectures* (pp. 440-452). Maggioli SpA with License Creative Commons CC BY-NC-ND 4.0.

# Struktur Bangunan Gridshell elastis GFRP memakai Pembelajaran Mesin (ML)

Dr. Ir. 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, ilmu sosiologi dan ilmu hukum. 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), Ilmu Perpajakan.

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 978-634-7695-15-4 (PDF)



9

786347

695154