

# AI & ML DI BIDANG KEUANGAN :

Mengatasi Masalah Kompleks dan Aplikasi Lingkungan,  
Sosial dan Tatakelola (ESG)

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



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

# AI & ML DI BIDANG KEUANGAN :

Mengatasi Masalah Kompleks dan Aplikasi Lingkungan,  
Sosial dan Tatakelola (ESG)



YAYASAN PRIMA AGUS TEKNIK

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

ISBN 978-634-7227-62-1 (PDF)



9 786347 227621

**AI DAN ML DI BIDANG KEUANGAN :**  
**Mengatasi Masalah Kompleks dan Aplikasi Lingkungan,**  
**Sosial dan Tatakelola (ESG)**

**Penulis :**

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

**ISBN : 978-634-7227-62-1 (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 dan syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa, karena berkat rahmat dan karunia-Nya buku berjudul ***“AI DAN ML DI BIDANG KEUANGAN: Mengatasi Masalah Kompleks dan Aplikasi Lingkungan, Sosial dan Tatakelola (ESG)”*** ini dapat diselesaikan. Buku ini hadir sebagai upaya memberikan pemahaman komprehensif mengenai penerapan kecerdasan buatan (AI) dan pembelajaran mesin (ML) dalam ranah keuangan yang semakin kompleks dan dinamis.

Bab demi bab dalam buku ini mengupas berbagai aspek penting mulai dari dasar-dasar AI dan ML dalam keuangan, aplikasi praktisnya dalam pengelolaan risiko, manajemen aset, hingga inovasi dalam strategi perdagangan dan peramalan keuangan. Selain itu, buku ini juga mengkaji secara mendalam integrasi prinsip-prinsip ESG yang kini menjadi penentu kunci dalam pengambilan keputusan keuangan yang bertanggung jawab secara lingkungan, sosial, dan tata kelola.

Bab pertama buku ini membahas konsep dasar AI dan ML serta bagaimana teknologi ini digunakan dalam sektor keuangan. Topik meliputi pengantar dan penjelasan perangkat untuk pengambilan keputusan berbasis data, sumber dan kualitas data yang relevan, pendekatan pemodelan inti, serta prinsip interpretabilitas, tata kelola, dan regulasi yang penting agar implementasi AI dan ML berjalan transparan dan akuntabel.

Bab kedua berfokus pada aplikasi praktis AI dan ML di berbagai aspek keuangan, seperti respons terhadap risiko, manajemen aset, strategi perdagangan, risiko kredit, efisiensi operasional, dan peramalan keuangan. Penjelasan mendalam mengenai bagaimana AI dapat meningkatkan kinerja dan inovasi dalam operasi pasar serta pengelolaan risiko keuangan disajikan di sini.

Bab ketiga akan mengulas bagaimana AI dan ML digunakan untuk mengintegrasikan faktor ESG ke dalam kerangka kerja dan keputusan keuangan. Termasuk pembahasan tentang metrik ESG dalam penyaringan portofolio, evaluasi kinerja, tantangan data ESG, serta aplikasi AI dalam manajemen risiko dan peluang yang terkait dengan lingkungan, sosial, dan tata kelola.

Bab 4 sekaligus menjadi bab terakhir ini menyoroti tantangan kompleksitas dan risiko sistem keuangan yang semakin dinamis akibat hadirnya AI. Diperinci penggunaan AI untuk menghadapi volatilitas dan menjaga stabilitas pasar. Selain itu, bab ini membahas implikasi etis dan sosial dari AI dalam keuangan, risiko sistemik yang mungkin muncul, perkembangan regulasi, dan tren masa depan terkait teknologi ini.

Penulis berharap buku ini dapat menjadi referensi penting bagi para akademisi, praktisi keuangan, pengembang teknologi, dan pembuat kebijakan yang ingin memahami bagaimana AI dan ML dapat membantu menghadapi tantangan kompleks di sektor keuangan sekaligus mengintegrasikan dimensi keberlanjutan melalui ESG.

Akhir kata, penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dan masukan selama proses penulisan buku ini. Semoga karya ini memberikan manfaat yang luas dan memperkaya khazanah ilmu pengetahuan di bidang kecerdasan buatan dan keuangan berkelanjutan.

Semarang, November 2025

Penulis

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

## DAFTAR ISI

<b>KATA PENGANTAR.....</b>	<b>ii</b>
<b>DAFTAR ISI.....</b>	<b>iii</b>
<b>BAB 1 KECERDASAN BUATAN DAN PEMBELAJARAN MESIN DALAM KEUANGAN .....</b>	<b>1</b>
1.1. Pendahuluan .....	1
1.2. Membingkai Perangkat Untuk Pengambilan Keputusan Berbasis Data .....	4
1.3. Sumber Data, Persiapan, Dan Pertimbangan Kualitas .....	6
1.4. Pendekatan Pemodelan Inti .....	11
1.5. Prinsip-Prinsip Interpretabilitas, Tata Kelola, Dan Regulasi .....	20
<b>BAB 2 APLIKASI KECERDASAN BUATAN DALAM KEUANGAN .....</b>	<b>27</b>
2.1. Menggunakan Kecerdasan Buatan/Pembelajaran Mesin Respons Risiko .....	27
2.2. Kecerdasan Buatan Dalam Manajemen Aset .....	27
2.3. Kecerdasan Buatan Dalam Strategi Perdagangan Dan Operasi Pasar .....	33
2.4. Kecerdasan Buatan Untuk Risiko Kredit Dan Inovasi Penilaian .....	39
2.5. Efisiensi Operasional Dan Otomatisasi Dengan Kecerdasan Buatan .....	48
2.6. Kecerdasan Buatan Dalam Peramalan Keuangan Dan Pemodelan Risiko .....	49
<b>BAB 3 KECERDASAN BUATAN DAN INTEGRASI ESG DALAM KEUANGAN.....</b>	<b>52</b>
3.1. Menanamkan Sinyal ESG Dalam Kerangka Kerja Keuangan Berbasis Data .....	52
3.2. Peran Kecerdasan Buatan Dan Pembelajaran Mesin.....	52
3.3. Metrik ESG Dalam Penyaringan Dan Evaluasi Portofolio .....	54
3.4. Faktor-Faktor ESG Dan Penilaian Kinerja .....	57
3.5. Tantangan Data ESG Dan Permintaan Pasar .....	59
3.6. Aplikasi Dalam Manajemen Risiko Dan Peluang Terkait ESG.....	62
<b>BAB 4 MENGELOLA KOMPLEKSITAS, RISIKO, DAN PERTIMBANGAN ETIKA .....</b>	<b>65</b>
4.2. Kompleksitas Dalam Sistem Keuangan Berbasis AI .....	65
4.3. Kecerdasan Buatan Untuk Volatilitas, Adaptasi, Dan Stabilitas Pasar .....	67
4.4. Implikasi Etis Dan Sosial Dari Kecerdasan Buatan Dalam Keuangan .....	70
4.5. Risiko Sistemik, Tren Regulasi, Dan Arah Masa Depan .....	72
5.6. Kesimpulan.....	75
<b>DAFTAR PUSTAKA .....</b>	<b>77</b>

## BAB 1

# KECERDASAN BUATAN DAN PEMBELAJARAN MESIN DALAM KEUANGAN

### 1.1 PENDAHULUAN

Kemajuan kecerdasan buatan (AI) dan pembelajaran mesin (ML) telah memengaruhi banyak sektor secara substansial, dengan sektor keuangan mengalami transformasi yang sangat signifikan. AI mengacu pada sistem komputasi yang dirancang untuk melakukan tugas-tugas yang umumnya berkaitan dengan kognisi manusia, termasuk pengambilan keputusan, persepsi, pemahaman bahasa, dan penalaran.

Dalam domain ini, ML memungkinkan sistem untuk meningkatkan kinerja melalui paparan data, tanpa memerlukan instruksi yang diprogram secara eksplisit. Algoritma ini sangat cocok untuk mengidentifikasi pola, menghasilkan prediksi, dan mendukung pengambilan keputusan secara real-time, terutama dalam konteks yang melibatkan data frekuensi tinggi dan multidimensi.

Dalam konteks keuangan, teknologi ini telah bertransisi dari alat otomasi eksperimental menjadi komponen integral dari sistem keputusan operasional dan strategis. Aplikasinya mencakup berbagai bidang seperti manajemen portofolio, perdagangan, evaluasi kredit, penilaian risiko, dan strategi investasi berorientasi keberlanjutan.

Implementasi awal di bidang keuangan dapat ditelusuri kembali ke model penilaian kredit otomatis dari tahun 1960-an dan 1970-an, yang mengandalkan teknik statistik seperti regresi linier dan logistik. Dekade berikutnya menyaksikan munculnya sistem pakar yang dirancang untuk meniru aturan keputusan, meskipun pendekatan ini terbukti terbatas dalam hal kemampuan adaptasi. Selama tahun 1990-an, metode pembelajaran mesin yang lebih fleksibel, seperti pohon keputusan dan mesin vektor pendukung (SVM), menjadi semakin menonjol.

Lanskap saat ini telah dibentuk oleh perkembangan infrastruktur komputasi, ketersediaan data, dan skalabilitas perangkat lunak. Sistem pembelajaran kontemporer mampu menganalisis kumpulan data kompleks secara waktu nyata (real-time), mendukung wawasan prediktif dan respons dinamis terhadap fluktuasi pasar. Kemampuan ini mendukung meningkatnya ketergantungan pada proses berbasis data di lembaga keuangan. Meskipun sistem-sistem awal utamanya digunakan untuk otomatisasi tugas atau peramalan ekonometrik dasar, aplikasi saat ini meluas hingga ke sistem pengambilan keputusan otonom. Jaringan saraf tiruan multi-lapis memfasilitasi pemodelan fenomena non-linier dalam peramalan, analisis teks, dan deteksi anomali. Data keuangan terstruktur dan sekuensial dapat diproses melalui arsitektur jaringan konvolusional dan rekuren, termasuk jaringan memori jangka pendek (LSTM), untuk aplikasi seperti prediksi harga dan deteksi anomali dalam aliran transaksi.

Pengambilan keputusan dalam lingkungan keuangan yang dinamis juga didukung oleh metode yang belajar melalui interaksi iteratif. Pendekatan ini telah diadopsi dalam

pengembangan strategi perdagangan dan proses alokasi portofolio yang menyesuaikan diri dengan data pasar yang terus diperbarui. Teknik-teknik ini menghadirkan fleksibilitas yang tidak terdapat dalam model optimasi tradisional dan memungkinkan agen keuangan untuk beroperasi di bawah ketidakpastian dengan peningkatan kemampuan adaptasi.

Integrasi di seluruh layanan keuangan sangat luas. Dalam manajemen investasi, layanan konsultasi yang dipersonalisasi kini diotomatisasi melalui sistem algoritmik yang mampu menyesuaikan portofolio dengan profil risiko dan tujuan keuangan individu. Alat-alat ini berkontribusi pada peningkatan aksesibilitas dan skalabilitas operasional.

Dalam operasi pasar, teknik pembelajaran mesin (ML) mendukung strategi frekuensi tinggi dan algoritma perdagangan adaptif yang mampu memodelkan inefisiensi jangka pendek. Model-model ini terus belajar dari informasi baru dan menyesuaikan strategi eksekusinya. Dalam evaluasi kredit, sumber informasi alternatif, termasuk data perilaku dan interaksi digital, semakin banyak diintegrasikan ke dalam pendekatan pemodelan, melengkapi indikator keuangan konvensional. Metode-metode ini meningkatkan akurasi prediktif dan inklusivitas, terutama bagi individu di luar cakupan sistem perbankan tradisional.

Dalam deteksi penipuan, identifikasi anomali waktu nyata dimungkinkan melalui algoritma pengenalan pola yang dilatih berdasarkan data transaksi historis. Sistem ini mendeteksi aktivitas tidak teratur tanpa label yang telah ditentukan sebelumnya, menggunakan metode pembelajaran tanpa pengawasan yang sangat sesuai untuk mendeteksi pola penipuan baru.

Metodologi yang mendasari perkembangan ini mencakup beragam pendekatan pembelajaran. Model terawasi digunakan secara luas untuk tugas-tugas peramalan dan klasifikasi, termasuk penilaian kredit dan prediksi volatilitas. Model tanpa pengawasan membantu dalam segmentasi dan identifikasi pola. Teknik-teknik yang didasarkan pada data berlabel terbatas, seperti metode semi-supervised dan self-supervised, semakin penting dalam domain keuangan di mana anotasi komprehensif tidak tersedia. Prapemrosesan data masukan merupakan fondasi bagi akurasi sistem. Prosedur seperti pembersihan, normalisasi, dan reduksi dimensionalitas berkontribusi pada peningkatan keandalan model. Dalam aplikasi data tekstual, langkah-langkah pemrosesan seperti stemming dan term filtering memfasilitasi peningkatan kinerja model. Persiapan data sangat penting untuk memastikan ketahanan dan konsistensi dalam prediksi keuangan.

Dalam situasi yang dicirikan oleh ketidakpastian, saling ketergantungan, dan nonlinieritas, kerangka kerja statistik tradisional seringkali terbukti tidak memadai. Pendekatan berbasis pembelajaran mendukung penilaian dan peramalan risiko dalam kondisi tersebut dengan mengidentifikasi ketergantungan laten dan beradaptasi dengan distribusi yang bergeser. Metode-metode ini sangat berguna untuk penetapan harga aset, evaluasi risiko sistemik, dan deteksi ancaman operasional.

Teknik pembelajaran mesin juga menunjukkan efikasi dalam menangani distribusi yang tidak teratur dan ketidakstabilan deret waktu, keduanya umum dalam data keuangan. Hal ini membuatnya sangat cocok untuk peramalan volatilitas, pengujian skenario, dan valuasi

derivatif. Model ensemble, metode pembelajaran transfer, dan optimasi Bayesian memberikan peningkatan lebih lanjut dalam akurasi prediksi dan kalibrasi ketidakpastian.

Keuangan yang berorientasi pada keberlanjutan merupakan ranah yang semakin relevan. Algoritma pembelajaran digunakan untuk menilai indikator terkait lingkungan, sosial, dan tata kelola (ESG) dengan menganalisis data terstruktur dan tidak terstruktur dari berbagai sumber, termasuk pengungkapan, konten tekstual, dan data sensor. Teknik-teknik ini mendukung penyusunan portofolio investasi berkelanjutan dan menginformasikan penilaian risiko yang sensitif terhadap metrik keberlanjutan.

Analisis data tidak terstruktur melalui perangkat pemrosesan bahasa memungkinkan ekstraksi sinyal yang relevan dari laporan keuangan, teks peraturan, dan wacana publik. Pelacakan sentimen dan penilaian reputasi mendapatkan manfaat dari model-model tersebut, terutama dalam konteks investasi yang sensitif terhadap ESG. Selain itu, kerangka kerja interpretabilitas model telah diusulkan untuk mengatasi ketidakjelasan sistem penilaian prediktif.

Meskipun terdapat kemajuan-kemajuan ini, masih terdapat beberapa kekhawatiran yang signifikan. Kekhawatiran ini meliputi keadilan, privasi, dan transparansi, terutama dalam model-model yang logika keputusannya sulit direkonstruksi. Sebagai respons, arah metodologi baru telah muncul, termasuk kerangka kerja interpretabilitas, protokol pembelajaran yang menjaga privasi, dan arsitektur komputasional baru. Perkembangan ini bertujuan untuk menyeimbangkan kinerja prediktif dengan prinsip akuntabilitas dan kontrol. Pelatihan model terdistribusi di seluruh institusi dapat meningkatkan perlindungan data, sementara paradigma komputasi yang baru muncul dapat mengatasi kendala skala dan kompleksitas. Arah ini menunjukkan pergeseran yang lebih luas menuju inovasi yang bertanggung jawab dalam pembelajaran mesin (ML) keuangan.

Tujuan buku ini ada tiga: i) menguraikan metodologi inti dan pendorong teknologi yang mendukung sistem AI di bidang keuangan; ii) mengeksplorasi aplikasinya di berbagai bidang seperti peramalan, perdagangan, konstruksi portofolio, deteksi penipuan, evaluasi kredit, dan keuangan berkelanjutan; iii) membahas tantangan etika, regulasi, dan metodologi yang akan membentuk masa depan ekosistem keuangan berbasis AI.

Struktur buku ini terbagi dalam empat bab. Bab 1 memberikan fondasi teknis sistem AI keuangan, yang meletakkan dasar untuk memahami metodologi kompleks yang terlibat. Bab 2 membahas pemodelan prediktif dan aplikasi berorientasi risiko, mengeksplorasi bagaimana AI dan ML digunakan untuk mengatasi tantangan dunia nyata di bidang keuangan. Pada Bab 3, fokus beralih ke peran AI dalam strategi keuangan, termasuk perilaku pasar dan integrasi prinsip-prinsip ESG. Terakhir, Bab 4 membahas tantangan terbuka dan tren yang muncul di bidang ini, termasuk AI yang dapat dijelaskan dan paradigma baru dalam pembelajaran mesin yang etis. Kesimpulannya merangkum wawasan utama dan menawarkan rekomendasi strategis bagi investor, pembuat kebijakan, dan peneliti.

Melalui eksplorasi ini, buku ini bertujuan untuk menyoroti potensi transformatif AI dan pembelajaran mesin di bidang keuangan, memberikan pembaca pengetahuan dan perangkat untuk menavigasi masa depan bidang yang berkembang pesat ini. Dengan membekali praktisi

dan akademisi dengan pemahaman yang lebih mendalam tentang kekuatan dan keterbatasan teknologi ini, buku ini juga bertujuan untuk mendorong pengembangan ekosistem keuangan berbasis AI yang tidak hanya efisien dan menguntungkan, tetapi juga etis, tangguh, dan selaras dengan tujuan sosial yang lebih luas.

## **1.2 MEMBINGKAI PERANGKAT UNTUK PENGAMBILAN KEPUTUSAN BERBASIS DATA**

Dalam beberapa tahun terakhir, kecerdasan buatan (AI) telah berevolusi dari perangkat eksperimental menjadi komponen dasar sistem keuangan modern. Lembaga keuangan, regulator, dan pembuat keputusan semakin mengandalkan AI untuk menangani volume dan variasi data yang terus bertambah karena pendekatan analitis tradisional seringkali gagal ketika data tidak lengkap, berisik, atau sangat dinamis. Model AI, dalam kondisi yang presisi, menawarkan model yang adaptif yang mampu mendeteksi pola, menghasilkan prakiraan, dan mendukung keputusan bahkan dalam skenario yang tidak pasti dan terus berkembang.

Bab ini memperkenalkan konsep dan metode inti di balik AI dan pembelajaran mesin (ML) dalam keuangan. Bab ini menjelaskan bagaimana teknologi ini digunakan untuk memproses data keuangan, mendukung pengambilan keputusan, dan mengatasi tantangan analitis. Bab ini menguraikan definisi, masalah persiapan data, dan berbagai strategi pemodelan, termasuk ML, pembelajaran mendalam (DL), pembelajaran penguatan (RL), dan pendekatan hibrida. Hal ini juga mencatat pentingnya interpretabilitas dan akuntabilitas seiring dengan semakin terintegrasinya model AI ke dalam operasi keuangan dan keterlibatannya yang mendalam dalam proses pengambilan keputusan dan manajemen risiko.

### **Mendefinisikan kecerdasan buatan dan pembelajaran mesin dalam konteks keuangan**

Dalam dekade terakhir, sektor keuangan telah mengalami transformasi yang didorong oleh semakin luasnya kapabilitas AI dan pembelajaran mesin. Sebelumnya terbatas pada inisiatif eksperimental atau strategi perdagangan khusus, teknologi ini telah menjadi fondasi bagi desain, operasi, dan regulasi sistem keuangan. Perkembangannya menandai perubahan dalam cara informasi keuangan diproduksi, dianalisis, dan digunakan. Berdasarkan asumsi ini, penelitian telah menelusuri difusi model-model ini di lingkungan akademis melalui analisis bibliometrik dan mendokumentasikan integrasinya ke dalam praktik kelembagaan melalui analisis konten.

AI secara luas didefinisikan sebagai bidang ilmiah yang berfokus pada penciptaan sistem komputasi yang mereplikasi proses kognitif manusia, termasuk mengenali pola, belajar dari pengalaman, bernalar, dan membuat keputusan yang terinformasi. AI dan ML berupaya mensimulasikan kecerdasan manusia dengan memungkinkan sistem memproses informasi kompleks, beradaptasi dengan masukan yang tidak lengkap, dan mendukung pengambilan keputusan di lingkungan yang tidak pasti. Dalam bidang yang lebih luas ini, ML mengacu pada algoritma yang meningkatkan kinerja seiring waktu dengan belajar langsung dari data tanpa pemrograman eksplisit untuk setiap tugas.

Adopsi AI dan ML merespons kompleksitas sistem keuangan, yang dicirikan oleh volume data yang besar, tidak lengkap, dan tidak terdistribusi normal, di mana model tradisional seringkali gagal dalam mendeteksi hubungan tersembunyi dan beradaptasi dengan

perubahan yang cepat. Dalam keuangan, ML telah diterapkan untuk mengatasi berbagai tantangan kompleks. Studi telah melaporkan model yang digunakan untuk mendeteksi transaksi penipuan dengan mengidentifikasi anomali halus, mengotomatiskan penilaian kredit melalui sumber data alternatif, mengoptimalkan strategi perdagangan intraday, dan memantau ketidakteraturan dalam dinamika pasar, yang menunjukkan potensinya untuk menangani masalah di luar metode statistik konvensional.

Meningkatnya penggunaan AI dan ML mencerminkan pergeseran dalam pengambilan keputusan, di mana keahlian manusia semakin dilengkapi oleh sistem berbasis data. Penelitian menyoroti penerapannya di berbagai fungsi keuangan. Misalnya, algoritma perdagangan berbasis sentimen mengintegrasikan sentimen yang berasal dari teks ke dalam model penetapan harga; sistem kepatuhan berbasis AI memantau transaksi secara real-time untuk pelanggaran regulasi; dan data alternatif, seperti citra satelit dan aktivitas web, digunakan untuk meningkatkan penilaian risiko kredit dan analisis investasi.

Upaya untuk mengklasifikasikan aplikasi AI dan ML telah menghasilkan kerangka kerja terstruktur yang mengidentifikasi domain-domain utama dampak. Sebuah taksonomi yang banyak dikutip menguraikan tujuh area utama: penilaian risiko kredit; deteksi dan pencegahan penipuan; strategi perdagangan dan manajemen aset; kepatuhan dan pelaporan regulasi; layanan pelanggan dan manajemen hubungan; sistem robo-advisory dan optimasi portofolio; serta risiko operasional dan otomatisasi proses.

Aplikasi-aplikasi ini mengintegrasikan kecerdasan real-time, adaptif, dan otomatis ke dalam operasi keuangan: misalnya, data transaksi langsung telah diintegrasikan ke dalam model risiko kredit untuk meningkatkan estimasi probabilitas gagal bayar, sementara sistem pemrosesan bahasa alami (NLP) telah diimplementasikan untuk menganalisis pengajuan peraturan secara otomatis dan mendeteksi aktivitas mencurigakan, sehingga meningkatkan pemantauan kepatuhan.

Faktor utama yang memungkinkan perluasan ini adalah kemampuan sistem AI untuk mengintegrasikan beragam sumber data. Studi telah menunjukkan bagaimana perangkat NLP dan model bahasa besar (LLM) memungkinkan analisis keuangan untuk menggabungkan data tidak terstruktur, seperti laporan analis, transkrip panggilan pendapatan, dan konten media sosial, mengekstraksi sentimen, sinyal risiko, dan wawasan prediktif dari informasi naratif. Menggabungkan data terstruktur dan tidak terstruktur juga telah terbukti meningkatkan deteksi pergeseran sentimen investor dan kondisi pasar. Kemajuan dalam komputasi awan, infrastruktur data yang skalabel, dan komputasi berkinerja tinggi telah memperluas akses ke perangkat AI dan ML di seluruh lembaga keuangan.

Bukti menunjukkan bahwa perusahaan besar, bank menengah dan kecil, serta perusahaan rintisan fintech telah memanfaatkan perkembangan ini untuk mengimplementasikan aplikasi AI dalam deteksi penipuan, perdagangan algoritmik, analitik pelanggan, dan manajemen portofolio. Namun, penerapan yang lebih luas meningkatkan kebutuhan akan validasi yang ketat, dokumentasi yang transparan, dan tata kelola yang kuat, terutama jika keluaran AI memengaruhi keputusan pemberian pinjaman, strategi investasi, atau kepatuhan regulasi.

Meskipun AI dan ML menyediakan kemampuan analitis dan prediktif yang berharga, penggunaannya menghadirkan tantangan regulasi, etika, dan organisasi. Para akademisi menekankan pentingnya transparansi, keadilan, interpretabilitas, dan akuntabilitas dalam aplikasi AI di bidang keuangan, sementara kerangka kerja regulasi terus berkembang untuk mendorong penggunaan AI yang bertanggung jawab. Aspek-aspek ini akan dibahas secara mendalam di Bagian 1.4.

Meskipun menghadapi tantangan dan kekhawatiran, aplikasi AI dan ML terus berkembang di berbagai aktivitas perdagangan, manajemen risiko, kepatuhan, dan konsultasi. Misalnya, model pembelajaran mendalam telah digunakan untuk mengembangkan strategi perdagangan yang beradaptasi secara dinamis terhadap volatilitas pasar, sementara sistem deteksi penipuan berbasis AI mendukung pemantauan transaksi secara real-time. Teknologi-teknologi ini telah bergeser dari inovasi opsional menjadi alat penting bagi lembaga yang ingin tetap kompetitif dalam lingkungan keuangan yang berbasis data dan inovasi.

### **1.3. SUMBER DATA, PERSIAPAN, DAN PERTIMBANGAN KUALITAS**

Data merupakan fondasi struktural bagi aplikasi AI dan ML di bidang keuangan, yang berfungsi sebagai basis bagi algoritma untuk memperoleh wawasan, prediksi, dan tindakan otomatis. Kapasitas model AI untuk mendukung proses pengambilan keputusan bergantung pada kelengkapan, keandalan, dan kesesuaian kontekstual dari input datanya. Data keuangan dicirikan oleh heterogenitasnya, yang mencakup kumpulan data terstruktur seperti neraca, catatan transaksi, harga saham, dan laporan kredit, di samping format tidak terstruktur yang diambil dari laporan analis, pengajuan peraturan, media berita, dan citra satelit.

Evolusi penting dalam sumber data keuangan adalah integrasi aliran data alternatif, yang melampaui batasan laporan akuntansi standar. Penelitian mendokumentasikan peningkatan penerapan sumber alternatif, termasuk pola penelusuran daring, aktivitas media sosial, data geolokasi, dan catatan konsumen tingkat transaksi, untuk melengkapi indikator keuangan tradisional. Data ini melengkapi metrik konvensional dengan memberikan sinyal proksimal sentimen konsumen, gangguan rantai pasok, dan peristiwa geopolitik, sehingga memperluas basis informasi yang tersedia untuk penilaian risiko dan analisis portofolio.

Pencarian data alternatif merupakan strategi di kalangan investor institusional dan manajer aset untuk mengakses keunggulan informasi yang tidak tersedia secara langsung melalui pengungkapan keuangan konvensional atau data pasar. Pendekatan ini mencerminkan semakin diakuinya bahwa kumpulan data tradisional, seperti neraca, laporan laba rugi, dan harga saham, mungkin sudah sepenuhnya terintegrasi ke dalam valuasi pasar, sehingga membatasi kemampuannya untuk memberikan keunggulan kompetitif dalam peramalan atau konstruksi portofolio. Sebaliknya, sumber data alternatif menawarkan potensi untuk mengungkap sinyal laten atau indikator utama yang mendahului siklus pelaporan resmi atau konsensus pasar.

Semakin banyak penelitian yang mendokumentasikan bagaimana citra satelit telah digunakan untuk mengkuantifikasi fenomena dunia nyata, mengubah masukan visual menjadi metrik terstruktur dan terukur yang menginformasikan keputusan investasi. Misalnya, analis

menggunakan observasi berbasis satelit untuk memperkirakan lalu lintas pejalan kaki ritel dengan menghitung mobil di tempat parkir, menilai hasil pertanian dengan memantau kesehatan tanaman, atau melacak aktivitas industri melalui pengukuran emisi pabrik atau kepadatan pelabuhan. Data spasial ini diproses menggunakan teknik pembelajaran mesin (ML) untuk menghasilkan indikator prediktif yang dapat mengantisipasi tren pendapatan, gangguan rantai pasok, atau kinerja sektoral sebelum perkembangan tersebut tercermin dalam laporan keuangan.

Secara paralel, metode pengikisan web otomatis telah dikembangkan untuk mengumpulkan data tekstual berskala besar dan tidak terstruktur dari berbagai platform daring. Dengan mengumpulkan informasi dari lowongan pekerjaan, ulasan konsumen, forum produk, dan aliran media sosial, analis dapat memperkaya model analisis sentimen dengan sinyal nontradisional yang menangkap perubahan perilaku konsumen, dinamika pasar tenaga kerja, atau risiko reputasi. Algoritma NLP diterapkan untuk mengurai dan mengkuantifikasi sinyal berbasis teks ini, mengintegrasikannya ke dalam kerangka kerja prediktif yang lebih luas yang digunakan dalam evaluasi kredit, riset ekuitas, dan manajemen portofolio.

Persiapan data mencakup serangkaian prosedur multidimensi yang bertujuan untuk mengubah data keuangan mentah, heterogen, dan seringkali tidak lengkap menjadi kumpulan data yang konsisten, andal, dan siap analisis. Proses ini merupakan prasyarat teknis untuk pemodelan dan penentu validitas, stabilitas, dan interpretabilitas hasil analisis berbasis AI. Pada intinya, persiapan data melibatkan langkah-langkah berurutan yang membahas kualitas, struktur, dan kegunaan data di berbagai sumber dan format. Komponen persiapan data meliputi operasi pembersihan data yang dirancang untuk mendeteksi dan mengoreksi kesalahan dan lonjakan, menghapus data duplikat, merekonsiliasi inkonsistensi dalam pelabelan atau klasifikasi, dan menyelaraskan variabel di berbagai standar pelaporan. Nilai yang hilang ditangani melalui teknik imputasi, mulai dari substitusi rata-rata sederhana hingga imputasi berbasis model yang lebih canggih, tergantung pada sifat dan tingkat kesenjangan data.

Rekayasa fitur merupakan langkah penting dalam alur kerja persiapan data, yang menggunakan transformasi, sintesis, atau pemilihan variabel untuk memfasilitasi pembelajaran model yang efektif. Misalnya, pembuatan metrik rasio, indikator volatilitas, dan skor sentimen mengubah data mentah menjadi representasi rekayasa yang selaras dengan tujuan prediktif. Analisis empiris menggarisbawahi bahwa efikasi prediktif model AI seringkali lebih bergantung pada relevansi dan kualitas fitur daripada algoritma pemodelan spesifik yang digunakan. Penelitian kontemporer juga mengeksplorasi pendekatan pembuatan fitur otomatis menggunakan algoritma ML untuk menyesuaikan set variabel secara dinamis sebagai respons terhadap aliran data yang masuk.

Pemrosesan data tak terstruktur menghadirkan kompleksitas metodologis yang berbeda. Metodologi NLP umumnya digunakan untuk mengekstraksi sinyal semantik dan sentimen dari teks tak terstruktur, termasuk artikel berita, dokumen hukum, atau komunikasi analis. Perkembangan LLM telah semakin memperluas kapasitas untuk menganalisis data naratif, memungkinkan pemodelan sentimen pasar, komunikasi korporat, dan wacana

geopolitik yang lebih canggih. Kerangka kerja integratif yang menggabungkan fitur turunan NLP dengan indikator numerik terstruktur telah menunjukkan peningkatan akurasi peramalan dengan menangkap sinyal lunak yang tidak dapat diakses melalui metrik kuantitatif murni.

Integrasi data terstruktur dan tak terstruktur memerlukan harmonisasi di berbagai format, frekuensi pelaporan, dan granularitas data. Studi menunjukkan bahwa menggabungkan modalitas ini meningkatkan ketahanan prediktif dengan menanamkan lapisan informasi yang saling melengkapi. Namun, integrasi semacam itu menimbulkan risiko metodologis, termasuk potensi overfitting atau sinyal yang kontradiktif jika protokol penyelarasan dan validasi data tidak diterapkan secara ketat). Kebutuhan akan metode penyelarasan temporal dan penyesuaian lag telah ditekankan dalam studi yang membahas tantangan rekonsiliasi sinyal sentimen yang diperbarui setiap hari dengan indikator keuangan yang hanya tersedia setiap kuartal.

Ketidaksesuaian temporal ini mencerminkan masalah yang lebih luas dalam integrasi data keuangan, di mana sinyal tak terstruktur berfrekuensi tinggi harus diharmonisasikan dengan siklus pelaporan terstruktur yang lebih lambat untuk menghindari inkonsistensi analitis atau korelasi palsu. Tanpa penyesuaian yang tepat, model dapat melebih-lebihkan relevansi prediktif sentimen kontemporer relatif terhadap fundamental keuangan yang tertinggal, yang menyebabkan inferensi yang menyesatkan atau kinerja prediktif yang tidak stabil.

Untuk mengatasi tantangan ini, berbagai metodologi telah diusulkan, termasuk penggunaan jendela agregasi bergulir, pelintiran waktu dinamis, dan penerapan struktur lag yang dikalibrasi melalui validasi historis. Teknik-teknik ini bertujuan untuk menyelaraskan konten informasi dari aliran data alternatif yang diperbarui secara cepat dengan pengungkapan keuangan berkala, sehingga menjaga koherensi temporal dan interpretabilitas ekonomi. Praktik-praktik ini didasarkan pada asumsi mengenai efisiensi pasar, difusi informasi, dan waktu reaksi investor, yang harus dipertimbangkan secara eksplisit dalam desain model

Metode pembelajaran mesin (ML) sedang dieksplorasi untuk mengotomatiskan penyelarasan temporal, memanfaatkan mekanisme atensi dan model sekuensial untuk mempelajari struktur lag optimal langsung dari data. Penelitian ini mencerminkan pergeseran menuju kerangka kerja adaptif yang mampu merekonsiliasi sumber data multi-frekuensi secara dinamis, terutama dalam konteks seperti perdagangan berbasis sentimen, pemodelan risiko kredit, dan peramalan berbasis peristiwa.

Perlu dicatat bahwa integrasi sinyal sentimen frekuensi tinggi dengan indikator keuangan frekuensi rendah menimbulkan tantangan tata kelola dan validasi. Prosedur penyelarasan harus memastikan transparansi, auditabilitas, dan ketahanan terhadap perubahan kondisi pasar, terutama ketika sinyal terintegrasi menginformasikan perdagangan, penilaian kredit, atau manajemen portofolio. Penyelarasan temporal dengan demikian memainkan fungsi metodologis dan tata kelola dalam aplikasi keuangan berbasis AI, yang menghubungkan proses integrasi data dengan tanggung jawab kelembagaan untuk pengawasan, akuntabilitas, dan kepatuhan.

Penilaian kualitas mencakup atribut-atribut seperti kelengkapan, akurasi, konsistensi, ketepatan waktu, dan relevansi kontekstual. Dataset keuangan sering kali menunjukkan kolom

yang hilang, siklus pelaporan yang tertunda, atau kesalahan yang berasal dari entri data manual atau format yang sudah usang. Studi menunjukkan bahwa kualitas data yang tidak memadai merusak keandalan model, yang menyebabkan keluaran yang terdistorsi dan berpotensi melanggar kewajiban regulasi. Oleh karena itu, langkah-langkah pengendalian kualitas harus mencakup algoritma deteksi anomali, audit berkala, perbandingan terhadap standar eksternal, dan pemantauan aliran input yang berkelanjutan. Praktik terbaik juga menekankan dokumentasi silsilah data yang kuat untuk menjaga ketertelusuran dan memfasilitasi akuntabilitas.

Selain pembersihan teknis, persiapan data dalam AI keuangan memerlukan intervensi eksplisit untuk mengatasi tantangan non-stasioneritas dan pergeseran distribusi. Data deret waktu dalam konteks keuangan jarang stasioner; Sifat statistiknya berkembang seiring dengan perubahan pasar struktural, intervensi kebijakan, atau guncangan ekonomi makro. Oleh karena itu, prapemrosesan harus mencakup pengujian stasioneritas, diferensiasi, atau teknik transformasi untuk memitigasi pola palsu dan mendorong dinamika pembelajaran yang stabil. Selain itu, akurasi dan integritas label yang digunakan dalam tugas pembelajaran terbimbing sangat penting; data yang salah label dapat menyebarkan kesalahan melalui sistem prediktif, sehingga memerlukan validasi prosedur pelabelan dan proses peninjauan yang melibatkan manusia untuk aplikasi berdampak tinggi.

Dimensi etika dan regulasi harus dipertimbangkan ketika praktik pengadaan dan persiapan data dipertimbangkan. Penggabungan data pribadi, perilaku, atau data yang berasal dari pengawasan menimbulkan risiko privasi dan kewajiban kepatuhan di bawah rezim seperti Peraturan Perlindungan Data Umum Uni Eropa (UE), GDPR. Lembaga keuangan diwajibkan untuk memastikan bahwa pengumpulan, penyimpanan, dan pemrosesan data mematuhi ketentuan hukum dan ekspektasi etika untuk memitigasi risiko sanksi dan kerusakan reputasi. Para penulis menyoroti pentingnya struktur tata kelola kelembagaan yang memantau kewajaran, keterwakilan, dan potensi efek diskriminatif yang tertanam dalam sumber data, terutama dalam aplikasi yang melibatkan keputusan kredit, penjaminan asuransi, atau deteksi penipuan.

Akses ke data fidelitas tinggi bervariasi antar pelaku keuangan. Lembaga besar dapat memperoleh akses istimewa ke kumpulan data kepemilikan, kemitraan data yang diperantarai, atau repositori data khusus, sementara lembaga yang lebih kecil atau baru mungkin mengandalkan kumpulan data publik atau vendor data pihak ketiga. Analisis menunjukkan bahwa disparitas tersebut membentuk posisi kompetitif, generalisasi algoritmik, dan risiko konsentrasi pasar. Para akademisi memperingatkan bahwa ketergantungan pada kumpulan data kepemilikan yang homogen dapat memperkuat kerentanan sistemik dengan menginduksi pola keputusan yang berkorelasi di seluruh model, sehingga meningkatkan kerapuhan pasar.

Kerangka kerja tata kelola data telah menjadi instrumen penting untuk mengawasi keandalan, transparansi, dan akuntabilitas keuangan berbasis AI. Struktur tata kelola mengartikulasikan peran, standar validasi, tanggung jawab pengelolaan data, dan protokol dokumentasi untuk meningkatkan integritas data. Literatur akademis menggarisbawahi bahwa tata kelola melampaui persyaratan kepatuhan, termasuk visibilitas ke dalam asal data,

dokumentasi alur kerja transformasi, dan mekanisme pengawasan manusia yang beroperasi bersama pemrosesan data otomatis. Proposal terbaru merekomendasikan komite etik data institusional untuk menyediakan pengawasan multidisiplin atas sistem pengambilan keputusan berbasis data berisiko tinggi.

Pendekatan yang muncul seperti pembangkitan data sintetis telah dieksplorasi sebagai strategi pelengkap untuk menambah kumpulan data yang terbatas atau memfasilitasi pembagian data yang menjaga privasi. Teknik data sintetis mensimulasikan contoh data yang representatif secara statistik yang berguna untuk pelatihan model dalam pengaturan seperti deteksi penipuan kejadian langka atau uji stres kontrafaktual. Namun, penelitian memperingatkan bahwa model pembangkitan data sintetis dapat secara tidak sengaja mereplikasi bias historis atau menimbulkan korelasi palsu jika korpus pelatihan kurang beragam atau representatif. Penting untuk dipahami bahwa data sintetis bertujuan untuk melengkapi, alih-alih menggantikan, sumber data autentik, terutama dalam aplikasi di mana kendala regulasi, etika, atau praktis membatasi akses langsung ke informasi sensitif.

Tabel 1.1 memberikan ikhtisar aktivitas persiapan data yang umum diterapkan dalam aplikasi AI dan ML di bidang keuangan, mensistematisasikan tugas dan contoh metode, serta menawarkan garis besar praktik yang terdokumentasi dalam literatur. Sesuai cakupan buku ini dan mempertimbangkan evolusi metodologi yang berkelanjutan di bidang ini, Tabel 1.1 tidak dimaksudkan untuk memberikan cakupan yang lengkap dari semua kemungkinan teknik persiapan data. Tujuannya adalah untuk merangkum aktivitas representatif yang mencerminkan pendekatan yang saat ini dibahas dan diimplementasikan dalam konteks AI keuangan.

**Tabel 1.1.** Aktivitas persiapan data dalam keuangan berbasis AI

<b>Aktivitas persiapan data</b>	<b>Contoh alat/Metode</b>	<b>Maksud/Sasaran</b>
Pembersihan data (deteksi kesalahan, penghapusan anomali)	Aturan validasi, deteksi anomali, dan skrip deduplikasi	Menghilangkan kesalahan input yang mendistorsi prediksi
Imputasi nilai yang hilang	Substitusi rata-rata, imputasi regresi, algoritma k-Nearest Neighbors (KNN), imputasi	Mempertahankan integritas statistik meskipun ada data yang hilang
Rekayasa fitur	Rasio, indikator volatilitas, skor sentimen, dan seleksi otomatis	Meningkatkan kinerja model melalui fitur prediktif
Pemrosesan data tidak terstruktur (NLP, LLM)	Alur kerja NLP, parser LLM, pengklasifikasi sentimen	Mengekstrak wawasan dari sumber tekstual/tidak terstruktur
Penyelarasan temporal	Jendela bergulir, pembengkokan waktu dinamis, kalibrasi lag	Sejajarkan data multi-frekuensi untuk pemodelan yang koheren
Integrasi data terstruktur + tidak terstruktur	Integrasi multimoda, fusi fitur	Gabungkan beragam data untuk wawasan yang lebih kaya

Pengujian dan transformasi stasioneritas	Uji Dickey-Fuller (ADF), uji KPSS, differencing, Box-Cox	Mitigasi masalah non-stasioneritas dalam deret waktu
Deteksi outlier dan koreksi spike	Pemfilteran Z-score, pengidentifikasi Hampel, winsorisasi	Koreksi nilai ekstrem yang menyebabkan bias pada model
Penilaian kualitas	Deteksi anomali, perbandingan, dan jejak audit	Pastikan data memenuhi standar kualitas
Tata kelola data dan dokumentasi silsilah	Sistem katalogisasi, repositori metadata, dan alat provenans	Dokumentasikan asal data untuk akuntabilitas
Pembangkitan data sintesis	Jaringan Adversarial Generatif (GAN), Variational Autoencoder (VAE), dan pembangkitan berbasis aturan	Tambahkan set data untuk kejadian langka atau kepatuhan privasi
Pemantauan pergeseran data dan penurunan kualitas	Alat validasi, pemantauan anomali, dan dasbor umpan balik	Deteksi degradasi data input untuk menjaga validitas model

Persiapan data dan manajemen kualitas dalam AI keuangan merupakan proses dinamis dan iteratif yang membutuhkan adaptasi terhadap sumber data yang terus berkembang, lingkungan regulasi yang terus berubah, dan konteks pasar yang sedang berkembang. Hal ini mencakup sistem pemantauan terintegrasi yang menggabungkan alat validasi statistik, mekanisme deteksi anomali, dan saluran umpan balik dari keluaran model untuk mendeteksi pergeseran data dan penurunan kualitas seiring waktu. Lembaga keuangan juga berinvestasi dalam repositori metadata dan sistem katalogisasi data untuk meningkatkan dokumentasi, transparansi, dan penggunaan kembali dataset.

Kualitas, keselarasan, dan tata kelola struktur data memengaruhi kinerja teknis dan legitimasi etika aplikasi AI. Mengembangkan arsitektur data yang transparan, dapat diaudit, dan selaras secara kontekstual diperlukan untuk memajukan integrasi AI yang bertanggung jawab, efektif, dan berkelanjutan dalam layanan keuangan. Bagian selanjutnya akan membahas bagaimana pendekatan pemodelan memanfaatkan aset data yang dikurasi ini untuk mendukung solusi keuangan yang prediktif, adaptif, dan otomatis.

#### 1.4. PENDEKATAN PEMODELAN INTI

Aplikasi AI di bidang keuangan bergantung pada beragam pendekatan pemodelan yang dirancang untuk beragam tujuan analitis dan prediktif. Pemilihan kerangka kerja pemodelan yang tepat melibatkan penyesuaian kapabilitas teknis dengan konteks keuangan, karakteristik data, dan persyaratan pengambilan keputusan yang spesifik.

Berbagai kategori pemodelan telah dikembangkan untuk menjawab tuntutan analisis keuangan yang bertujuan memecahkan masalah keuangan kompleks yang telah lama dianggap belum terselesaikan. Tantangan yang dibahas berkaitan dengan pertanyaan penelitian yang secara historis gagal memberikan jawaban yang konvergen atau memuaskan dari model yang

ada. Pertanyaan terbuka ini seringkali berkaitan dengan isu-isu yang sangat praktis yang solusinya secara tradisional bergantung pada pengamatan deret waktu historis. Namun, pendekatan ini mengungkapkan keterbatasan ketika data historis tidak lengkap, ditandai dengan deret yang pendek, atau ketika data menunjukkan distribusi yang tidak normal. Keterbatasan tersebut menjadi lebih jelas ketika deret data menunjukkan anomali akibat peristiwa ekstrem dalam distribusi. Tantangan analitis semakin intensif dalam kondisi kompleksitas pasar yang tinggi, seperti lingkungan keuangan kontemporer.

Dengan adanya fenomena diskontinu atau patahan struktural, analisis yang hanya didasarkan pada data historis terbukti tidak memadai. Lebih lanjut, analisis skenario kompleks membutuhkan model yang mampu mengidentifikasi pola dan sinyal laten, yang memungkinkan respons yang tidak hanya deskriptif tetapi juga prediktif, atau bahkan antisipatif. Kebutuhan akan analisis prediktif dalam konteks kompleks ini menggambarkan alasan untuk melengkapi model inferensi linear klasik dengan pendekatan alternatif, yaitu model yang adaptif, mampu belajar melalui proses pelatihan, dan dirancang untuk menangani hubungan dinamis dan nonlinier tanpa mengandaikan struktur parametrik yang tetap.

Perbedaan mendasar dalam pendekatan pemodelan AI adalah antara pembelajaran terawasi dan tanpa pengawasan. Pembelajaran terawasi bergantung pada kumpulan data berlabel untuk melatih model yang mampu memprediksi hasil berdasarkan fitur masukan. Kelompok ini mencakup tugas klasifikasi dan regresi, di mana data historis menyediakan prediktor dan hasil yang diketahui. Contoh di bidang keuangan antara lain penilaian kredit, di mana peminjam dikategorikan berdasarkan perilaku pembayaran kembali; deteksi penipuan, di mana transaksi diberi label sebagai penipuan atau sah; dan sistem persetujuan pinjaman yang memprediksi probabilitas gagal bayar. Dengan demikian, pembelajaran yang diawasi memungkinkan lembaga untuk mengotomatiskan proses pengambilan keputusan di mana hasil historis tersedia untuk pelatihan.

Sebaliknya, pembelajaran tanpa pengawasan diterapkan ketika tidak ada label hasil yang tersedia, dan tujuannya adalah untuk mengungkap pola, pengelompokan, atau struktur tersembunyi dalam data. Contoh pembelajaran tanpa pengawasan di bidang keuangan meliputi pengelompokan klien ke dalam segmen-segmen untuk strategi pemasaran yang dipersonalisasi, mendeteksi transaksi anomali yang mungkin mengindikasikan pola penipuan yang sebelumnya tidak diketahui, atau mengidentifikasi faktor-faktor yang mendasari pengembalian saham melalui teknik reduksi dimensionalitas seperti analisis komponen utama (PCA). Model-model ini sangat berguna dalam analisis data eksploratif, mengungkap struktur yang mungkin tidak dihipotesiskan sebelumnya.

Tabel 1.2 memberikan gambaran umum perbandingan model terawasi dan tanpa pengawasan yang digunakan dalam aplikasi AI di bidang keuangan, merangkum definisi, tujuan, algoritma, persyaratan input, output, aplikasi, kekuatan, dan keterbatasan. Tabel ini menawarkan sintesis beberapa karakteristik dan kasus penggunaan yang terdokumentasi dalam literatur akademis.

**Tabel 1.2.** Gambaran Umum Model Terawasi dan Tanpa Pengawasan dalam AI untuk Keuangan

Karakteristik dan kasus penggunaan	Model terawasi	Model tanpa pengawasan
Definisi	Belajar dari data berlabel dengan pasangan input-output yang diketahui	Pelajari pola dari data tak berlabel tanpa keluaran yang telah ditentukan sebelumnya
Tujuan	Memprediksi variabel target atau mengklasifikasikan instance baru	Temukan struktur, kluster, atau hubungan dalam data
Algoritma umum	Pohon keputusan, hutan acak, SVM, regresi logistik, jaringan neural	K-means, pengelompokan hierarkis, PCA, autoencoder
Data masukan	Memerlukan dataset berlabel	Menggunakan dataset tak berlabel
Keluaran	Prediksi atau klasifikasi spesifik	Pengelompokan data, reduksi dimensionalitas, deteksi anomali
Aplikasi keuangan	Penilaian kredit, deteksi penipuan, dan prediksi kebangkrutan	Segmentasi pelanggan, deteksi penipuan, dan analisis faktor untuk imbal hasil saham
Kekuatan	Akurasi tinggi dengan data berlabel yang memadai, dapat diinterpretasikan dalam model yang lebih sederhana	Berguna untuk data besar tak berlabel, karena mengungkap struktur tersembunyi
Keterbatasan	Memerlukan data berlabel, risiko overfitting	Hasil lebih sulit divalidasi, interpretasi mungkin kurang langsung

Masing-masing pendekatan pemodelan ini akan dibahas dalam subbagian berikut dengan perspektif keuangan, membahas landasan teoritis, implementasi praktis, dan aplikasi di seluruh domain keuangan.

### **Pembelajaran Mesin: Pendekatan Klasifikasi dan Regresi**

Berdasarkan ikhtisar konseptual yang disajikan di Bagian 1.2, bagian ini berfokus pada model pembelajaran mesin terawasi untuk klasifikasi dan regresi, yang merupakan pendekatan dasar dalam aplikasi keuangan. Teknik pembelajaran mesin terawasi mempelajari hubungan prediktif dari data berlabel, mengembangkan fungsi yang memetakan fitur input ke hasil yang diketahui. Penerapannya mencerminkan kebutuhan akan perangkat yang adaptif dan berbasis data yang mampu mendukung pengambilan keputusan dalam lingkungan yang dicirikan oleh informasi yang tidak lengkap, beragam, dan terus berkembang.

Model pembelajaran mesin terawasi digunakan untuk menangani dua tugas utama: klasifikasi, yang menetapkan observasi ke dalam kategori diskrit, dan regresi, yang memprediksi nilai kontinu. Di bidang keuangan, model klasifikasi telah banyak digunakan dalam penilaian kredit (mengkategorikan peminjam ke dalam kelas risiko), deteksi penipuan (mengklasifikasikan transaksi sebagai penipuan atau sah), dan prediksi kebangkrutan.

Algoritma klasifikasi yang umum mencakup pohon keputusan, hutan acak, SVM, regresi logistik, dan pengklasifikasi jaringan saraf tiruan. Masing-masing pendekatan ini memiliki karakteristik yang berbeda dalam hal sensitivitas terhadap karakteristik data, kebutuhan komputasi, dan interpretabilitas.

Di antaranya, hutan acak, yang diperkenalkan oleh Breiman (2001), telah banyak didokumentasikan penggunaannya dalam tugas klasifikasi keuangan. Struktur ansambelnya, yang menggabungkan beberapa pohon keputusan, meningkatkan stabilitas prediksi dan mengurangi overfitting dibandingkan dengan model pohon tunggal. Aplikasi hutan acak dalam keuangan mencakup prediksi gagal bayar kredit, klasifikasi kebangkrutan, dan deteksi penipuan, yang memanfaatkan kapasitasnya untuk memodelkan hubungan dan interaksi nonlinier tanpa memerlukan asumsi parametrik. SVM, di sisi lain, efektif untuk klasifikasi dalam ruang berdimensi tinggi, terutama ketika batas antar kelas tidak dapat dipisahkan secara linier.

Model regresi dalam pembelajaran mesin bertujuan untuk memprediksi hasil yang berkelanjutan berdasarkan fitur masukan. Aplikasi keuangan mencakup peramalan imbal hasil aset, estimasi probabilitas gagal bayar, dan proyeksi volatilitas pasar. Model regresi linier masih banyak digunakan karena kesederhanaan dan transparansinya, namun metode nonlinier seperti regresor pohon keputusan, regresi kernel ridge, dan regresi vektor pendukung telah menunjukkan keunggulan dalam memodelkan dependensi nonlinier yang terdapat dalam data keuangan.

Sebagaimana dibahas di Bagian 1.3, rekayasa fitur dan persiapan data memainkan peran penting dalam memungkinkan pemodelan ML yang efektif. Bagian ini berfokus pada bagaimana algoritma ML tertentu menggabungkan pemilihan fitur atau ukuran kepentingan fitur dalam proses pemodelannya, sehingga menghindari duplikasi pembahasan sebelumnya.

Pohon keputusan secara inheren melakukan pemilihan fitur dengan mengevaluasi pemisahan data berdasarkan kriteria seperti perolehan informasi atau ketidakmurnian Gini. Dalam hutan acak, kepentingan fitur sering dinilai melalui ukuran seperti penurunan rata-rata ketidakmurnian atau kepentingan berbasis permutasi, yang memungkinkan praktisi untuk mengidentifikasi variabel yang paling berkontribusi terhadap akurasi prediktif. SVM bergantung pada fungsi kernel untuk mentransformasi fitur ke dalam ruang berdimensi lebih tinggi, dan meskipun tidak menyediakan ukuran kepentingan fitur yang eksplisit, teknik seleksi fitur (misalnya, eliminasi fitur rekursif) umumnya diterapkan bersamaan dengan pelatihan SVM untuk mengurangi dimensionalitas dan meningkatkan kinerja model.

Metode ensemble seperti boosting juga mengintegrasikan pembobotan fitur implisit dengan secara progresif menekankan instans yang salah klasifikasi, sehingga menyesuaikan kepentingan fitur di seluruh iterasi. Jaringan saraf tiruan, meskipun fleksibel, biasanya dipandang kurang dapat diinterpretasikan terkait kontribusi fitur; pendekatan seperti analisis sensitivitas, propagasi relevansi lapis demi lapis, atau model pengganti digunakan untuk memperkirakan pengaruh input-fitur.

Tabel 1.3 memberikan ringkasan model pembelajaran mesin terawasi yang umum digunakan di bidang keuangan, metode tipikal mereka untuk seleksi fitur atau penilaian kepentingan, dan referensi terpilih.

**Tabel 1.3.** Ikhtisar model pembelajaran mesin terawasi, metode seleksi fitur, dan aplikasi keuangan

Model ML	Teknik Seleksi Fitur/Kepentingan	Contoh aplikasi keuangan
Pohon keputusan	Kriteria pemisahan (Gini, entropi), seleksi fitur implisit	Penilaian kredit, deteksi penipuan
Hutan acak	Pengotoran penurunan rata-rata, kepentingan permutasi	Prediksi gagal bayar, prediksi kebangkrutan
SVM	Eliminasi fitur rekursif, metode filter	Penilaian kredit, deteksi penipuan
Regresi logistik	Metode filter (korelasi), seleksi bertahap	Pemodelan risiko kredit, persetujuan pinjaman
Peningkatan gradien	Pembobotan fitur tertanam selama iterasi peningkatan	Penilaian kredit, deteksi penipuan
Jaringan saraf tiruan	Analisis sensitivitas, model pengganti	Peramalan pasar, deteksi anomali

Area minat yang terus berlanjut dalam pembelajaran mesin finansial adalah tantangan generalisasi model dengan adanya multikolinearitas, fitur redundan, atau variabel yang bising. Temuan empiris menunjukkan bahwa menghilangkan fitur yang tidak relevan atau tidak stabil meningkatkan ketahanan prediktif dan mengurangi overfitting. Strategi pemilihan fitur dapat berbasis filter (misalnya, ambang batas korelasi), berbasis wrapper (misalnya, eliminasi rekursif), atau tertanam dalam algoritma itu sendiri, tergantung pada model dan tugas yang dipilih.

Dalam praktiknya, lembaga yang mengadopsi model pembelajaran mesin terawasi sering kali menyeimbangkan akurasi, kelayakan komputasi, dan kendala operasional saat memilih algoritma. Model yang lebih sederhana seperti regresi logistik dan pohon keputusan mungkin memadai ketika transparansi dan kecepatan diprioritaskan. Model yang lebih kompleks, seperti hutan acak atau pohon terdorong, dipilih ketika akurasi prediktif dalam konteks nonlinier sangat penting, meskipun dengan tantangan komputasi dan interpretabilitas yang lebih tinggi.

Meskipun rekayasa fitur dan interpretabilitas dibahas masing-masing di Bagian 1.3 dan 1.5, penting untuk dicatat secara singkat bahwa model pembelajaran mesin tersupervisi memerlukan validasi yang kuat dan kerangka kerja pemantauan berkelanjutan untuk mempertahankan relevansi prediktif dalam kondisi pasar yang terus berkembang. Praktik seperti validasi silang, pengujian di luar sampel, dan pengujian ulang merupakan standar untuk mengevaluasi generalisasi model dan mendeteksi overfitting. Mekanisme pemantauan diperlukan untuk mengatasi pergeseran konsep, yang menyebabkan hubungan antara fitur dan variabel target bergeser seiring waktu, yang berpotensi menurunkan kinerja model.

Untuk spesifikasi algoritmik, prosedur pelatihan, dan detail implementasi komputasional model pembelajaran mesin yang dibahas dalam bab ini, pembaca dapat merujuk ke Alpaydin (2021), Pengantar Pembelajaran Mesin, yang memberikan cakupan dasar tentang desain algoritma, optimasi model, dan strategi implementasi untuk aplikasi keuangan.

### **Pembelajaran mendalam dan pembelajaran penguatan**

Pembelajaran mendalam (DL) dan pembelajaran penguatan (RL) merupakan pendekatan pemodelan canggih dalam ranah AI yang lebih luas, memperluas perangkat metodologis untuk mengatasi permasalahan yang kompleks, berdimensi tinggi, nonlinier, dan dinamis di bidang keuangan. Pendekatan ini telah memungkinkan pengembangan model yang mampu mempelajari pola-pola rumit dari kumpulan data besar, mendukung tugas-tugas pengambilan keputusan prediktif dan sekuensial dalam lingkungan keuangan.

DL dibangun di atas arsitektur jaringan saraf tiruan yang terdiri dari beberapa lapisan yang saling terhubung yang dirancang untuk mempelajari representasi fitur hierarkis langsung dari data. Struktur berlapis ini memungkinkan model DL mengurangi ketergantungan pada rekayasa fitur manual, suatu aspek yang telah dibahas di Bagian 1.3. Di bidang keuangan, teknik DL telah diterapkan pada berbagai kasus penggunaan yang melibatkan data terstruktur dan tidak terstruktur. Contohnya meliputi ekstraksi sentimen dari artikel berita keuangan, analisis sinyal media sosial, pemrosesan informasi tekstual dari transkrip panggilan pendapatan, dan identifikasi pola laten dalam data perdagangan frekuensi tinggi.

Arsitektur pembelajaran mesin (DL) yang umum diterapkan dalam konteks keuangan meliputi jaringan saraf tiruan konvolusional (CNN) dan jaringan saraf tiruan berulang (RNN), terutama jaringan memori jangka panjang (LSTM). CNN telah digunakan untuk memproses citra satelit guna memantau aktivitas industri, yang memungkinkan wawasan investasi dari sumber data alternatif. RNN dan LSTM efektif untuk memodelkan data yang bergantung waktu, sehingga cocok untuk tugas-tugas seperti prediksi harga saham, peramalan volatilitas, dan optimasi portofolio sekuensial.

Kemampuan model DL untuk menangkap hubungan nonlinier dan kompleks telah dimanfaatkan dalam aplikasi seperti deteksi penipuan dan penilaian kredit, terutama ketika polanya halus dan terdistribusi di berbagai variabel. Penelitian menyoroti bahwa DL meningkatkan kinerja klasifikasi dalam kumpulan data skala besar di mana model tradisional mungkin kesulitan mendeteksi interaksi laten.

Terlepas dari kapasitas prediktifnya, model DL menghadirkan tantangan operasional terkait tuntutan komputasi dan berkurangnya interpretabilitas. Tantangan-tantangan ini, termasuk implikasinya terhadap kepatuhan regulasi, dibahas di Bagian 1.5.

RL memperkenalkan paradigma pembelajaran yang berbeda berdasarkan interaksi dengan lingkungan untuk mengoptimalkan kebijakan pengambilan keputusan berurutan. Alih-alih belajar dari pasangan input-output berlabel, agen RL belajar memetakan status ke tindakan dengan memaksimalkan imbalan kumulatif. Pendekatan ini selaras dengan konteks pengambilan keputusan keuangan yang membutuhkan adaptasi terhadap lingkungan yang dinamis dan umpan balik yang tertunda.

Penerapan RL dalam keuangan mencakup perdagangan algoritmik, alokasi portofolio dinamis, dan strategi pembentukan pasar. Dengan mensimulasikan lingkungan perdagangan, agen RL dapat mengembangkan strategi dalam berbagai kondisi likuiditas, volatilitas, dan biaya transaksi, menyempurnakan kebijakan berdasarkan struktur imbalan yang terkait dengan profitabilitas atau kendala risiko.

Integrasi DL dengan RL telah menghasilkan kerangka kerja pembelajaran penguatan mendalam (DRL), yang memungkinkan agen untuk memproses data masukan berdimensi tinggi, seperti dinamika buku pesanan dan indikator sentimen, sambil mempelajari strategi adaptif di berbagai rezim pasar. DRL telah dieksplorasi untuk mengoptimalkan eksekusi perdagangan, mengelola portofolio multi-aset, dan bereaksi terhadap sinyal berbasis peristiwa secara real-time.

Namun, penerapan RL dan DRL dalam praktik keuangan menghadapi kendala, termasuk persyaratan data dan simulasi yang tinggi, sensitivitas terhadap desain fungsi imbalan, dan potensi ketidakstabilan dalam pembelajaran kebijakan. Para peneliti menekankan pentingnya pemantauan, validasi, dan uji stres model untuk memitigasi risiko generalisasi yang buruk atau perilaku strategi yang tidak diinginkan.

Pendekatan hibrida yang menggabungkan keluaran pembelajaran langsung (DL) dan pembelajaran langsung (RL) dengan sistem berbasis aturan atau heuristik pakar telah diusulkan untuk menyeimbangkan pembelajaran adaptif dengan batasan domain, menciptakan sistem yang mengintegrasikan wawasan berbasis data dengan pengetahuan institusional.

### **Model Hibrida dan Teknik Ensemble**

Dalam aplikasi keuangan AI, model hibrida dan teknik ensemble menjadi area minat yang berkembang karena kemampuannya untuk mengintegrasikan beragam perspektif algoritmik dan meningkatkan kinerja prediktif di berbagai konteks. Pendekatan-pendekatan ini muncul sebagai respons terhadap keterbatasan inheren masing-masing model ketika diterapkan pada kumpulan data yang kompleks, berdimensi tinggi, atau heterogen, karakteristik yang seringkali menentukan lingkungan keuangan.

Model hibrida didefinisikan sebagai sistem yang menggabungkan dua atau lebih teknik AI atau ML yang berbeda untuk menciptakan arsitektur komposit. Model-model ini bertujuan untuk memanfaatkan kekuatan berbagai algoritma sekaligus mengurangi kelemahan masing-masing. Misalnya, para peneliti telah mengusulkan arsitektur di mana metode pembelajaran berbasis pembelajaran (DL) digunakan untuk ekstraksi fitur dari data tak terstruktur, sementara algoritma ML tradisional seperti mesin penguat gradien (GBM) atau mesin vektor pendukung diterapkan untuk tugas klasifikasi atau regresi pada fitur yang diekstraksi. Integrasi ini meningkatkan kapasitas model untuk memproses hubungan non-linier, dependensi temporal, dan struktur laten yang mungkin tidak cukup ditangkap oleh satu jenis model saja. Sebaliknya, metode ensemble berfokus pada penggabungan beberapa model dengan tipe yang sama atau berbeda untuk mengagregasi prediksi.

Model-model ini tidak memerlukan integrasi eksplisit dari berbagai paradigma pemodelan dalam struktur komputasi yang sama, melainkan mengandalkan penggabungan

keluaran dari beberapa model yang telah dilatih. Teknik ensemble secara luas dikategorikan menjadi bagging, boosting, dan stacking. Setiap pendekatan menggunakan mekanisme yang berbeda untuk meningkatkan ketahanan model, mengurangi varians, atau meningkatkan generalisasi.

Bagging (agregasi bootstrap) melatih beberapa instans model dasar pada subset data pelatihan yang berbeda, biasanya diambil sampelnya dengan penggantian. Hasilnya diagregasi, seringkali melalui pemungutan suara mayoritas untuk klasifikasi atau perata-rataan untuk regresi. Strategi ini mengurangi varians dan mencegah overfitting. Dalam keuangan, bagging umumnya digunakan dalam penilaian kredit dan pemodelan risiko, di mana stabilitas model sangat penting.

Boosting melibatkan pelatihan model secara berurutan di mana setiap model berikutnya mencoba mengoreksi kesalahan pendahulunya. Algoritma seperti AdaBoost dan XGBoost telah menunjukkan akurasi tinggi dalam peramalan keuangan, deteksi penipuan, dan prediksi risiko kredit. Algoritma ini memberikan bobot yang lebih tinggi pada observasi yang sulit diprediksi, sehingga menghasilkan model yang beradaptasi dengan pola data yang kompleks.

Penumpukan (generalisasi bertumpuk) melibatkan pelatihan beberapa pembelajar dasar dan menggabungkan prediksi mereka melalui meta-pembelajar. Meta-model belajar untuk menimbang kontribusi setiap model dasar, yang berpotensi mengoptimalkan kinerja melalui pencampuran model yang cerdas. Arsitektur ini telah diterapkan dalam algoritma perdagangan, sistem persetujuan kredit, dan tugas segmentasi pelanggan.

Pendekatan hibrida dan ansambel menawarkan keunggulan utama dalam ranah keuangan:

- Pendekatan ini dapat meningkatkan generalisasi model dengan mengintegrasikan keluaran dari model yang berbeda dalam hal asumsi, struktur, atau strategi pembelajaran.
- Pendekatan ini mendukung analisis sumber data multimoda, seperti indikator numerik, deret waktu, dan data tekstual, dengan menetapkan komponen yang berbeda ke tipe data yang berbeda.
- Pendekatan ini meningkatkan ketahanan terhadap overfitting dengan merata-ratakan bias model individual.

Namun, model-model ini juga menimbulkan kekhawatiran terkait kompleksitas, interpretabilitas, dan biaya komputasi. Integrasi beberapa paradigma pembelajaran seringkali meningkatkan opasitas model, sehingga mempersulit prosedur validasi dan penjelasan. Sebagaimana dibahas di Bagian 1.5, lembaga keuangan harus menanamkan arsitektur tersebut dalam kerangka tata kelola yang menyediakan ketertelusuran, pemantauan, dan dokumentasi.

Secara praktis, sistem hibrida dan ansambel telah diimplementasikan dalam optimasi portofolio, pemodelan risiko, analisis sentimen pasar, dan strategi perdagangan frekuensi tinggi. Misalnya, pengklasifikasi sentimen berbasis DL dapat dimasukkan ke dalam model ansambel yang digunakan untuk prediksi pasar jangka pendek. Demikian pula, arsitektur

hibrida telah dieksplorasi untuk prediksi kebangkrutan dengan mengintegrasikan pengungkapan tekstual dengan indikator kuantitatif.

Studi empiris menyoroti manfaat kinerja dari teknik-teknik ini. Penelitian telah menunjukkan bahwa model ansambel mengungguli algoritma tunggal dalam estimasi risiko gagal bayar dan dalam mengidentifikasi outlier dalam data transaksi. Temuan ini telah mendorong adopsi praktik ansambel oleh perusahaan fintech dan manajer aset institusional yang bertujuan untuk meningkatkan akurasi keputusan dalam ketidakpastian.

Meskipun teknik hibrida dan ansambel secara teknis menjanjikan, penerapannya di bidang keuangan memerlukan penilaian yang cermat terhadap trade-off antara akurasi prediktif, interpretabilitas, dan kepatuhan regulasi. Lembaga harus memastikan bahwa logika ansambel didokumentasikan dan kerangka kerja manajemen risiko model memperhitungkan interdependensi antar model komponen. Dalam konteks ini, pembelajaran ensemble seharusnya dipandang bukan sebagai pengganti transparansi model, melainkan sebagai komponen dalam strategi pemodelan yang lebih luas yang menyeimbangkan kompleksitas dengan akuntabilitas institusional.

Setelah pembahasan di bagian ini dan bagian ini, Tabel 1.4 memberikan sintesis komparatif kategori-kategori utama model AI yang diterapkan di bidang keuangan, yang membedakan antara pembelajaran terawasi, tanpa pengawasan, pembelajaran penguatan, pembelajaran mendalam, konfigurasi hibrida, dan teknik ensemble. Setiap kategori diuraikan berdasarkan representasi algoritmiknya, aplikasi keuangan, kekuatan, dan keterbatasannya, dengan referensi yang didasarkan pada literatur empiris dan teoretis.

**Tabel 1.4.** Ikhtisar kategori dan aplikasi model AI di bidang keuangan

Jenis model	Contoh algoritma	Aplikasi keuangan	Keunggulan	Keterbatasan
Pembelajaran terawasi	Pohon keputusan, regresi logistik, SVM, RF	Penilaian kredit, deteksi penipuan, dan prediksi gagal bayar	Akurasi tinggi dengan data berlabel, dapat diinterpretasikan dalam model yang lebih sederhana	Membutuhkan data berlabel, rentan terhadap overfitting
Pembelajaran tanpa pengawasan	K-means, DBSCAN, PCA, dan autoencoder	Segmentasi pelanggan, deteksi anomali	Berguna dengan data tak berlabel, mendeteksi struktur tersembunyi	Lebih sulit divalidasi, interpretasinya mungkin kurang intuitif
Pembelajaran penguatan	Q-learning, DQN, metode gradien kebijakan	Strategi perdagangan, optimasi portofolio dinamis	Kemampuan beradaptasi terhadap lingkungan, belajar melalui interaksi	Kompleksitas pelatihan, sensitivitas desain penghargaan

Pembelajaran mendalam	CNN, RNN, LSTM, transformer	Analisis sentimen, perdagangan frekuensi tinggi	Memproses data tak terstruktur, menangkap dependensi nonlinier	Transparansi rendah, biaya komputasi tinggi
Model hibrida	DL + ML (misalnya, CNN + SVM)	Prediksi kebangkrutan, peramalan yang ditingkatkan sentimen	Memanfaatkan beragam kekuatan, baik untuk data multimoda	Kompleksitas meningkat dan transparansi berkurang
Teknik ansambel	Bagging, boosting (XGBoost), stacking	Risiko kredit, optimasi portofolio, analitik pelanggan	Mengurangi varians, meningkatkan generalisasi, dan beradaptasi dengan data kompleks	Opasitas model tinggi, kompleksitas tata kelola

*Catatan:* RF = Hutan Acak, DBSCAN = Pengelompokan Spasial Berbasis Kepadatan Aplikasi dengan Derau, SVM = Mesin Vektor Pendukung, CNN = Jaringan Saraf Konvolusional, RNN = Jaringan Saraf Rekuren, LSTM = Memori Jangka Pendek Panjang, DQN = Jaringan Q Dalam.

### 1.5. PRINSIP-PRINSIP INTERPRETABILITAS, TATA KELOLA, DAN REGULASI

Penerapan AI dan ML dalam sistem keuangan membutuhkan kerangka kerja yang komprehensif untuk interpretabilitas, tata kelola, dan penyesuaian regulasi. Seiring dengan semakin terintegrasinya model AI dalam rantai pengambilan keputusan keuangan, lembaga harus menerapkan prosedur untuk memastikan transparansi, konsistensi, dan akuntabilitas di seluruh penerapan model. Ini mencakup praktik teknis untuk dokumentasi dan validasi, serta mekanisme kelembagaan untuk pengawasan dan kepatuhan.

Interpretabilitas mengacu pada sejauh mana aktor manusia dapat memahami logika dan struktur keluaran model. Dalam ranah keuangan, interpretabilitas berkaitan dengan persyaratan kepatuhan regulasi, auditabilitas, dan validasi internal, terutama dalam konteks yang melibatkan penilaian kredit, alokasi investasi, deteksi penipuan, dan operasi kepatuhan. Kurangnya interpretabilitas dapat menghambat transparansi dan menantang tanggung jawab kelembagaan.

Topik interpretabilitas, proses dan keluaran model, telah lama menjadi prioritas baik dalam konteks akademis maupun operasional, terutama terkait penerapan proses pengambilan keputusan yang terinformasi di bidang keuangan, yang didukung oleh verifikasi data, analisis, dan validasi keluaran yang ketat, bahkan sebelum era model AI. Alasan di balik hal ini adalah bahwa keputusan keuangan dan strategi operasional seringkali memiliki implikasi yang melampaui batas-batas masing-masing lembaga. Lembaga keuangan saling terkait erat satu sama lain dan dengan perekonomian riil, yang menjadikan stabilitas dan efisiensi mereka sebagai prioritas regulasi dan operasional.

Risiko yang terkait dengan operasional bank dan lembaga keuangan dengan demikian diatur oleh tata kelola internal dan ketentuan regulasi khusus yang dirancang untuk menegakkan pendekatan kehati-hatian dan meningkatkan perlindungan investor serta praktik manajemen risiko. Misalnya, perhatikan perhatian regulasi dan metodologis yang dicurahkan untuk memitigasi risiko kredit, pasar, operasional, dan likuiditas di perbankan dan, baru-baru ini, perhatian untuk mengevaluasi dan memitigasi dampak risiko iklim terhadap lembaga perantara perbankan dan asuransi.

Interpretabilitas proses dan keluaran model mengambil peran yang semakin krusial karena model AI semakin banyak digunakan tidak hanya untuk mendukung tetapi juga menggantikan pendekatan tradisional dalam pengambilan keputusan keuangan. Penerapannya di bidang keuangan telah didorong oleh meningkatnya kompleksitas skenario makroekonomi selama dua dekade terakhir, yang ditandai oleh diskontinuitas dan keretakan struktural, yang secara signifikan telah menantang kecukupan model inferensi tradisional. Namun, karena tingkat kecanggihan dan otonomi "cerdas" yang menjadi ciri fungsinya, sebagaimana telah diuraikan di Bagian 1.4, model AI menghadirkan tingkat transparansi yang lebih rendah dibandingkan dengan model tradisional, yang seringkali berfungsi sebagai kotak hitam yang sesungguhnya.

Pengamatan ini telah mendorong komunitas ilmiah dan operasional untuk menyerukan refleksi baru tentang peran interpretabilitas dan transparansi. Memang, sistem keuangan kontemporer, mengingat peran sentralnya dalam mendukung transisi sistem ekonomi dan sosial yang lebih luas menuju kesetaraan, transparansi, dan keberlanjutan yang lebih baik, tidak dapat bergantung pada ramalan yang samar. Sebaliknya, sistem ini harus menyeimbangkan kembali proses inovasi yang luar biasa ini dengan mengadopsi pedoman baru dan spesifik yang memastikan penggunaan yang bertanggung jawab.

Interpretabilitas model AI memang sangat bervariasi tergantung pada arsitektur yang mendasarinya. Model dengan struktur yang secara inheren transparan, seperti regresi linier, pohon keputusan, dan pengklasifikasi berbasis aturan, memungkinkan para pemangku kepentingan untuk melacak bagaimana fitur input memengaruhi prediksi. Model-model ini biasanya mengasumsikan linearitas, monotonisitas, atau aturan keputusan yang didefinisikan secara eksplisit, sehingga dapat diakses oleh auditor, petugas kepatuhan, dan pengguna non-teknis.

Sebaliknya, model yang lebih kompleks atau buram, seperti yang berbasis DL, RL, dan konfigurasi hibrida, bergantung pada transformasi nonlinier dan teknik optimasi adaptif. Model-model ini sering kali dicirikan oleh ruang laten berdimensi tinggi dan interaksi yang sulit diinspeksi. Meskipun menawarkan keunggulan dalam pemodelan data tak terstruktur, deret waktu frekuensi tinggi, dan dependensi nonlinier, model-model ini menghadirkan tantangan dalam hal transparansi dan penjelasan.

Untuk mendukung pemahaman model AI, berbagai teknik interpretabilitas post-hoc telah dikembangkan. Teknik-teknik ini meliputi pemeringkatan kepentingan fitur, pemodelan surrogate, visualisasi ketergantungan parsial, dan metode penjelasan lokal seperti SHAP dan LIME. SHAP (Shapley Additive exPlanations) menggabungkan interpretabilitas lokal dan global

dengan mengatribusikan kontribusi setiap fitur input terhadap prediksi model berdasarkan teori permainan kooperatif. Metode ini banyak digunakan karena konsistensi dan sifat aditifnya. LIME (Local Interpretable Model-agnostic Explanations) mengaproksimasi model kompleks secara lokal menggunakan model interpretable yang lebih sederhana, menawarkan penjelasan yang mudah dipahami, terutama pada data tabular dan berbasis teks. Namun, terlepas dari kegunaannya, alat-alat ini memperkenalkan lapisan abstraksi yang dapat salah mengartikan atau menyederhanakan mekanisme model yang sebenarnya. Meskipun penjelasan post-hoc meningkatkan pemahaman, penjelasan tersebut tidak selalu sepenuhnya selaras dengan internal model dan berpotensi menyesatkan pengguna non-ahli.

Dalam keuangan, konsep-konsep ini bersinggungan dengan tata kelola internal dan regulasi pengawasan, di mana lembaga harus mampu menunjukkan alasan di balik keputusan terkait alokasi kredit, strategi perdagangan, deteksi penipuan, dan pemantauan kepatuhan. Model yang tidak memberikan transparansi yang memadai dapat menghambat pelaporan regulasi, meningkatkan risiko operasional, atau mengorbankan kepercayaan pengguna. Lebih lanjut, ketergantungan pada penjelasan yang disederhanakan menimbulkan risiko institusional, terutama dalam aplikasi seperti penilaian kredit, penjaminan emisi, atau perdagangan otomatis.

Sebagai respons, institusi dapat mengadopsi model yang secara inheren dapat diinterpretasikan, seperti pohon keputusan, model aditif tergeneralisasi, dan pengklasifikasi berbasis aturan, yang memberikan keluaran terstruktur dan terlacak. Namun, sebagaimana dijelaskan di Bagian 1.4, model-model ini masih terbatas dalam aplikasi yang melibatkan data berdimensi tinggi atau tidak terstruktur, yang membutuhkan arsitektur yang lebih kompleks untuk mengidentifikasi hubungan nonlinier dan sinyal laten. Ketika model tersebut tidak memungkinkan, teknik interpretabilitas harus diintegrasikan ke dalam kerangka kerja tata kelola yang mendukung ketertelusuran, dokumentasi, dan supervisi.

Dalam konteks ini, penting untuk membedakan antara tata kelola internal dan tata kelola kelembagaan, yang keduanya merupakan komponen fundamental dan pelengkap dari kerangka kerja AI yang bertanggung jawab. Tata kelola internal mengacu pada serangkaian mekanisme teknis dan prosedural dalam suatu organisasi yang memandu pengembangan, penerapan, dan pemantauan model AI. Tata kelola ini melibatkan pendefinisian peran operasional, penetapan standar dokumentasi, validasi keluaran, pemantauan kinerja, dan penyesuaian perilaku model dengan tujuan manajemen risiko dan kebutuhan kepatuhan.

Tingkat tata kelola ini beroperasi terutama di dalam departemen teknis dan fungsional, memastikan konsistensi, auditabilitas, dan kepatuhan regulasi di tingkat model. Agar efektif dalam domain yang menantang ini, protokol tata kelola internal harus mencakup semua fase penerapan model, termasuk peran, prosedur, dokumentasi teknis, validasi keluaran dan pemantauan kinerja, serta strategi manajemen risiko yang dimaksudkan untuk menyelaraskan perilaku model dengan tujuan kelembagaan dan persyaratan kepatuhan.

Dokumentasi, validasi, dan pemantauan merupakan komponen penting tata kelola model: dokumentasi harus mencakup tujuan model, metodologi pengembangan, asumsi, sumber data, dan kriteria evaluasi kinerja; prosedur validasi sering kali mencakup validasi

silang, pengujian di luar sampel, uji stres, dan penilaian kinerja dalam kondisi yang berubah, serta mekanisme pemantauan pergeseran konsep dan pergeseran data; sistem pemantauan dapat mencakup dasbor, pemicu validasi, dan protokol pelatihan ulang. Mekanisme ini memastikan bahwa kinerja model tetap selaras dengan tujuan institusi dari waktu ke waktu.

Tata kelola institusi beroperasi pada tingkat strategis dan organisasi. Tata kelola ini mencakup serangkaian kebijakan, prinsip etika, selera risiko, dan struktur pengawasan yang lebih luas yang menentukan bagaimana AI tertanam dalam strategi jangka panjang dan budaya risiko institusi. Inti dari lapisan tata kelola ini adalah komite risiko model, yang biasanya terdiri dari perwakilan kepatuhan, hukum, teknis, dan manajemen risiko, serta mekanisme eskalasi untuk keputusan berdampak tinggi dan pengawasan risiko reputasi dan etika.

Tata kelola internal memastikan integritas teknis dan keandalan operasional model AI, sementara tata kelola institusional melengkapinya dengan mendorong keselarasan dengan misi, tanggung jawab sosial, dan kewajiban regulasi organisasi. Dalam kerangka kerja berlapis ganda ini, institusi menetapkan tanggung jawab yang jelas untuk kepemilikan, pemeliharaan, dan intervensi model, serta menetapkan fungsi kontrol yang mencakup audit model, pemantauan bias, dan prosedur validasi kinerja.

Dua dimensi operasional yang sangat penting untuk mengefektifkan kerangka kerja tata kelola: ketertelusuran dan deteksi bias, yang dengannya prinsip-prinsip tata kelola ditegakkan dan diaudit. Sebagaimana dibahas di Bagian 1.3, ketertelusuran berfungsi sebagai mekanisme tata kelola inti untuk menghubungkan masukan data, arsitektur model, dan hasil keputusan. Hal ini memungkinkan lembaga untuk merekonstruksi bagaimana suatu hasil tertentu dihasilkan, siapa yang bertanggung jawab, dan apakah hasil tersebut mematuhi kebijakan internal dan regulasi eksternal. Untuk memastikan hal ini, lembaga harus mendokumentasikan transformasi data, memelihara repositori metadata, dan secara sistematis melacak iterasi dan pembaruan model. Praktik-praktik ini mendukung reproduktifitas, memfasilitasi analisis insiden, dan menegakkan standar integritas dan transparansi data.

Secara paralel, deteksi dan mitigasi bias sangat penting untuk mengoperasionalkan komitmen tata kelola terhadap keadilan, legalitas, dan perlindungan reputasi. Proses-proses ini melibatkan identifikasi pola diskriminatif dalam data pelatihan atau perilaku model, mengaudit kewajaran keluaran, dan menerapkan koreksi teknis atau prosedural ketika disparitas teramati. Struktur tata kelola memformalkan bagaimana evaluasi semacam itu dilakukan, seberapa sering terjadi, dan proses remediasi apa yang dipicu jika terjadi kegagalan. Alat-alat seperti debiasing adversarial, peluang yang disamakan, dan metrik kewajaran kelompok memainkan peran yang semakin penting dalam manajemen kewajaran AI operasional. Topik-topik ini juga dibahas secara rinci di Bagian 4.3.

Lebih lanjut, ketika model dan sumber data yang serupa digunakan di berbagai lembaga, kontrol ketertelusuran dan kewajaran menjalankan fungsi sistemik. Ketidakhadirannya dapat memperkuat risiko yang berkorelasi dan menyebabkan distorsi di seluruh pasar. Penelitian menunjukkan bahwa ketergantungan yang meluas pada alat yang seragam dapat memperburuk prosiklikalitas dan meningkatkan paparan kolektif terhadap

kegagalan dalam kondisi stres. Fungsi tata kelola ini juga meluas ke sistem AI yang dialihdayakan dan pihak ketiga. Lembaga harus memasukkan persyaratan ketertelusuran dan kewajaran ke dalam pengaturan kontraktual mereka untuk memastikan akuntabilitas, bahkan ketika menggunakan perangkat lunak yang bersifat kepemilikan. Dokumentasi, hak audit, dan akses ke metrik kinerja harus dijamin.

Tata kelola AI memang membutuhkan pengawasan yang cermat terhadap bagaimana sistem otomatis berinteraksi dengan aktor manusia. Lembaga harus menetapkan ambang batas yang jelas untuk intervensi, protokol eskalasi, dan mekanisme penggantian untuk memastikan bahwa keputusan dengan konsekuensi hukum, etika, atau keuangan tetap berada di bawah kendali manusia yang bertanggung jawab.

Meskipun integrasi AI dalam pengambilan keputusan keuangan menimbulkan pertanyaan kritis tentang interpretabilitas dan tata kelola dalam perusahaan, hal ini juga mentransformasi praktik pengawasan. Otoritas keuangan semakin banyak menggunakan perangkat berbasis AI, yang umumnya disebut sebagai Teknologi Pengawas (SupTech), yang digunakan untuk meningkatkan cakupan, kecepatan, dan ketepatan pengawasan regulasi. Perkembangan ini, yang dibahas secara mendalam di Bab 4, menandakan pergeseran menuju kerangka kerja pengawasan berbasis digital yang selaras dengan dinamika keuangan algoritmik.

Sistem regulasi juga berkembang untuk mengatasi meningkatnya penggunaan AI di berbagai lembaga keuangan. Di tingkat Eropa, inisiatif regulasi seperti Undang-Undang AI menetapkan persyaratan khusus untuk dokumentasi, transparansi, dan pengawasan. Salah satu perhatian paling relevan bagi regulator adalah bagaimana sistem otomatis berinteraksi dengan pengambilan keputusan manusia. Sebagaimana secara eksplisit diakui dalam Undang-Undang AI Eropa (Peraturan (EU) 2024/1689 Parlemen Eropa dan Dewan tanggal 13 Juni 2024), sistem AI berisiko tinggi, termasuk yang diterapkan dalam layanan keuangan, harus tetap tunduk pada pengawasan manusia yang memadai. Persyaratan regulasi ini memperkuat prinsip inti tata kelola: AI harus dirancang untuk meningkatkan, bukan menggantikan, penilaian profesional. Oleh karena itu, lembaga harus menetapkan protokol tata kelola yang menentukan ambang batas intervensi manusia, menyertakan mekanisme eskalasi, dan menerapkan prosedur pengesampingan untuk keputusan yang membawa konsekuensi hukum, etika, atau keuangan yang signifikan.

Otoritas Perbankan Eropa (EBA) dan Komite Basel juga telah menekankan pentingnya mengintegrasikan tata kelola model AI ke dalam kerangka kerja pengawasan yang ada. Berdasarkan Peraturan Persyaratan Modal (CRR), model internal, termasuk yang digunakan untuk memperkirakan eksposur kredit atau risiko operasional, diharuskan dapat diinterpretasikan, divalidasi secara independen, dan didokumentasikan secara memadai. Di luar Uni Eropa, beberapa yurisdiksi lain telah mengeluarkan panduan pelengkap yang dirancang khusus untuk pengawasan model AI dalam konteks keuangan. Di Amerika Serikat, ekspektasi pengawasan yang diuraikan dalam SR 11-7, bersama dengan upaya berkelanjutan oleh Komisi Sekuritas dan Bursa (SEC) dan Biro Perlindungan Keuangan Konsumen (CFPB), menggarisbawahi perlunya dokumentasi, transparansi, dan mitigasi diskriminasi.

Demikian pula, Otoritas Perilaku Keuangan Inggris dan Bank of England telah menetapkan prinsip-prinsip untuk penggunaan AI yang bertanggung jawab. Di Singapura, Otoritas Moneter memperkenalkan prinsip-prinsip FEAT untuk mendorong keadilan, etika, akuntabilitas, dan transparansi dalam sistem berbasis data. AS, Kanada, dan negara-negara lain juga sedang mengembangkan kerangka regulasi yang menggabungkan persyaratan tata kelola AI bagi lembaga keuangan, khususnya untuk penilaian dan pemberian pinjaman kredit (misalnya, Undang-Undang Kesempatan Kredit Setara AS, ECOA).

**Tabel 1.5.** Aspek interpretabilitas, tata kelola, dan regulasi dalam AI keuangan

<b>Fungsi</b>	<b>Alat/Metode</b>	<b>Keunggulan</b>	<b>Keterbatasan</b>
Interpretabilitas	Model linear, pohon keputusan, SHAP, LIME, plot ketergantungan parsial, model pengganti	Meningkatkan transparansi dan auditabilitas; memungkinkan pemahaman pemangku kepentingan; mendukung pelaporan regulasi	Mungkin terlalu menyederhanakan model yang kompleks; penerapannya terbatas pada model yang mendalam; potensi salah tafsir
Tata Kelola Internal	Protokol validasi, dokumentasi model, pemantauan dasbor, dan deteksi penyimpangan (misalnya, penyimpangan konsep, penyimpangan data)	Memastikan konsistensi dan keandalan model; menyelaraskan model dengan tujuan institusional; mendukung akuntabilitas	Membutuhkan banyak sumber daya; memerlukan pembaruan berkelanjutan; mungkin kesulitan dengan model yang berkembang pesat
Tata Kelola Kelembagaan	Komite etik AI, komite risiko model, penyesuaian kebijakan strategis, pengawasan pihak ketiga	Menyelaraskan AI dengan etika dan kepatuhan organisasi; mendukung budaya risiko jangka panjang	Mungkin menghadapi resistensi organisasi; kesulitan dalam penerapan di seluruh departemen atau vendor
Bias dan Keadilan	Debias adversarial, peluang yang disamakan, rasio dampak yang berbeda, audit kewajaran	Mengidentifikasi dan memitigasi diskriminasi; mendukung kepatuhan etika dan hukum; meningkatkan kepercayaan model	Kompleks untuk diimplementasikan dan dievaluasi; terdapat kompromi dengan akurasi; standar hukum yang terus berkembang
Ketertelusuran dan Dokumentasi	Repositori metadata, kontrol versi, alat silsilah data, dan log audit model Undang-Undang AI Uni Eropa, GDPR, ECOA, SR 11-7,	Mendukung reproduktifitas; memungkinkan analisis retrospektif; penting untuk kepatuhan	Dapat menjadi rumit dan mahal, tergantung pada kematangan teknis lembaga

Kepatuhan Regulasi	Otoritas Moneter Singapura (MAS) Keadilan, Etika, Akuntabilitas, dan Transparansi (FEAT), integrasi audit internal	Memastikan kepatuhan terhadap kerangka hukum; meningkatkan kepercayaan pasar dan konsumen	Persyaratan peraturan dapat bervariasi di berbagai yurisdiksi; terdapat risiko regulasi yang berlebihan
--------------------	--	---	---

Mengingat lanskap regulasi yang semakin luas ini, badan pengawas dapat meminta analisis skenario, penilaian dampak, pelaporan bias dan kinerja, serta penjelasan rinci tentang perilaku model dan pengendalian risiko terkait. Untuk memenuhi harapan ini, lembaga disarankan untuk membentuk komite etik AI internal, menerapkan strategi pembelajaran berkelanjutan, dan mendorong kolaborasi multidisiplin antara tim hukum, teknis, dan kepatuhan. Lebih lanjut, kerangka kerja tata kelola juga harus mencakup sistem AI yang dialihdayakan atau pihak ketiga. Kontrak dengan penyedia eksternal harus menjamin akses lembaga terhadap dokumentasi, hak audit, dan data kinerja. Bahkan, ketika lembaga mengandalkan perangkat proprietary, tata kelola harus mencakup perlindungan kontraktual yang menjamin akuntabilitas dan transparansi.

Bersama-sama, interpretabilitas, tata kelola, dan standar regulasi merupakan fondasi struktural bagi penerapan model AI yang bertanggung jawab di bidang keuangan. Dengan menanamkan transparansi, pengawasan manusia, dan kepatuhan hukum ke dalam prosedur khusus, praktik dokumentasi, dan kerangka kerja organisasi, lembaga dapat mendorong inovasi dan akuntabilitas dalam sistem keuangan berbasis AI.

## BAB 2

### APLIKASI KECERDASAN BUATAN DALAM KEUANGAN

#### 2.1. MENGGUNAKAN KECERDASAN BUATAN/PEMBELAJARAN MESIN RESPONS RISIKO

Metode AI dan ML telah membentuk kembali lanskap pengambilan keputusan keuangan di seluruh manajemen investasi, perdagangan, risiko kredit, dan optimalisasi operasional. Bab ini menyajikan kajian berbasis sektor tentang bagaimana model AI diterapkan dalam lembaga keuangan untuk mendukung analisis investasi, alokasi portofolio, evaluasi kredit, eksekusi perdagangan, dan efisiensi operasional. Setiap bagian berfokus pada domain aplikasi tertentu, dimulai dengan manajemen aset dan layanan konsultasi yang dipersonalisasi, hingga meluas ke infrastruktur perdagangan dan sistem risiko kredit. Bab ini juga membahas penggunaan AI untuk meningkatkan kinerja operasional melalui otomatisasi dan optimalisasi proses.

Pembahasan ini menghubungkan teknik pemodelan yang diperkenalkan pada Bab 1 dengan aplikasi di dunia nyata, menyediakan jembatan konseptual ke kasus penggunaan yang dieksplorasi dalam keuangan berkelanjutan dan tata kelola risiko sistemik pada bab-bab selanjutnya. Susunan bab ini mengikuti logika domain keuangan praktis: pertama, bagaimana AI mendukung desain dan personalisasi investasi; kemudian, bagaimana AI beroperasi di lingkungan pasar untuk perdagangan; diikuti oleh penggunaannya dalam risiko kredit, optimasi operasional, dan pemodelan risiko berwawasan ke depan. Struktur tematik ini mencerminkan diferensiasi fungsional dan fleksibilitas teknologi aplikasi AI di bidang keuangan.

#### 2.2. KECERDASAN BUATAN DALAM MANAJEMEN ASET

AI telah menjadi semakin integral dalam manajemen aset, di mana penerapannya mendukung peningkatan kapasitas analitis, pengambilan keputusan adaptif, dan otomatisasi proses investasi yang kompleks. Model AI diterapkan di beberapa aktivitas yang berbeda namun saling terkait, termasuk konstruksi portofolio, alokasi aset, optimasi risiko-imbalance hasil, pemantauan kinerja, dan personalisasi klien. Setiap aktivitas memanfaatkan wawasan berbasis data untuk menginformasikan dan menyesuaikan strategi investasi secara real-time.

AI dapat mendukung konstruksi portofolio melalui teknik-teknik canggih yang meningkatkan diversifikasi tradisional dan trade-off risiko-imbalance hasil. Model pembelajaran terawasi digunakan untuk memperkirakan imbalance hasil dan volatilitas aset, menggabungkan data terstruktur (misalnya, harga, fundamental) dan sumber tidak terstruktur (misalnya, laporan analis, indikator sentimen). Model seperti hutan acak dan jaringan saraf tiruan digunakan untuk memeringkat aset atau memprediksi imbalance hasil, sementara metode tanpa pengawasan seperti pengelompokan membantu mengidentifikasi kelompok aset dengan perilaku serupa, yang mendukung strategi diversifikasi.

Model pembelajaran terawasi seperti hutan acak, GBM, dan perseptron multilapis umumnya digunakan untuk memperkirakan imbalance hasil aset, volatilitas, atau ukuran risiko penurunan. Model-model ini memanfaatkan input terstruktur (misalnya, harga historis,

pendapatan, rasio leverage) dan fitur tidak terstruktur (misalnya, komentar analis atau sentimen media) untuk menghasilkan peringkat aset dan prediksi imbal hasil.

Model peramalan juga dapat mencakup indikator peringatan dini pergeseran rezim dengan menggabungkan sinyal berwawasan ke depan seperti spread kredit, kurva komoditas berjangka, atau indeks sentimen investor. Metode pembelajaran tanpa pengawasan meningkatkan strategi diversifikasi dengan mengelompokkan aset-aset dengan perilaku temporal atau profil eksposur risiko yang serupa. Teknik seperti pengelompokan k-means, model campuran Gaussian, atau peta pengorganisasian mandiri (SOM) mengidentifikasi struktur tersembunyi dalam ruang imbal hasil aset, memandu konstruksi keranjang dengan korelasi intra-grup yang lebih rendah dan heterogenitas lintas-grup yang lebih tinggi.

Teknik hibrida dan ansambel semakin meningkatkan ketahanan dan adaptabilitas konstruksi portofolio berbasis AI. Misalnya, pendekatan bagging dan boosting dapat memitigasi varians model, sementara ansambel bertumpuk menggabungkan kekuatan beberapa pembelajar basis. Beberapa aplikasi menggabungkan model analisis sentimen berbasis arsitektur transformer dengan pembelajar terawasi, meningkatkan reaktivitas terhadap perubahan nada pasar atau arus berita spesifik perusahaan. Dalam pengaturan ini, keterjelasan menjadi perhatian, terutama ketika alat interpretabilitas post-hoc digunakan untuk menghubungkan sinyal ke bobot portofolio (lihat Bagian 1.5 untuk pembahasan terperinci).

Penelitian telah menunjukkan bahwa mengintegrasikan pembelajaran mesin dengan optimasi mean-variance tradisional meningkatkan kinerja, terutama dalam menangani distribusi non-normal dan menangkap pergeseran rezim. Contohnya termasuk penerapan autoencoder untuk mengidentifikasi fitur laten di seluruh kelas aset dan menggabungkannya ke dalam algoritma optimasi portofolio.

Dari perspektif alokasi aset, pembelajaran penguatan (RL) menyediakan kerangka kerja optimasi dinamis. Agen RL mengalokasikan modal secara adaptif dengan memaksimalkan fungsi imbalan yang bergantung pada biaya transaksi, penarikan dana, atau kendala risiko. Implementasi RL yang mendalam, seperti Deep Deterministic Policy Gradient (DDPG) atau Proximal Policy Optimization (PPO), cocok untuk masalah alokasi berdimensi tinggi dengan ruang aksi kontinu.

Agen-agen ini secara iteratif mempelajari kebijakan optimal melalui simulasi interaksi pasar atau uji coba ulang rolling window. Misalnya, agen telah dilatih untuk menggeser alokasi secara dinamis di seluruh ekuitas, obligasi, dan komoditas sebagai respons terhadap volatilitas dan pergeseran korelasi. AI juga dapat meningkatkan alokasi strategis melalui peramalan makroekonomi dan deteksi rezim. Dengan memodelkan berbagai lintasan makroekonomi, algoritma dapat mengidentifikasi dependensi tersembunyi dan faktor laten yang memengaruhi harga aset, mendukung alokasi yang lebih terinformasi di berbagai geografi, sektor, dan instrumen. Misalnya, jaringan LSTM telah digunakan untuk mendeteksi titik balik pasar dan memprediksi rezim volatilitas, sehingga meningkatkan penyeimbangan kembali aset taktis.

Teknik analisis skenario yang didukung AI memungkinkan uji stres alokasi dalam berbagai skenario hipotetis. Pembuatan data sintetis dan model simulasi adversarial (misalnya, Jaringan Adversarial Generatif, GAN) digunakan untuk mensimulasikan peristiwa langka dan menguji ketahanan portofolio. Kemampuan untuk menggabungkan input berdimensi tinggi, termasuk sinyal ESG dan kumpulan data alternatif, memungkinkan pemahaman kontekstual yang lebih luas tentang perilaku aset. Teknik dan tantangan spesifik ESG dalam proses investasi dibahas lebih lanjut dalam Bab 3, yang berfokus pada integrasi AI dan ESG dalam keuangan berkelanjutan.

Terkait manajemen risiko dan pemantauan kinerja, model AI dapat menawarkan dukungan untuk memfasilitasi pemantauan berkelanjutan kinerja portofolio, memberikan peringatan dini dan diagnostik untuk deviasi dari eksposur risiko target. Analisis deret waktu menggunakan RNN atau LSTM memungkinkan deteksi pergeseran dalam struktur volatilitas atau korelasi, sementara algoritma deteksi anomali menandai pola kinerja yang tidak terduga.

Diagnostik kinerja semakin bergantung pada prakiraan probabilistik dan kuantifikasi ketidakpastian. Model Bayesian dan kerangka kerja ensemble menghasilkan interval kepercayaan di sekitar estimasi imbal hasil, yang mendukung pelacakan kinerja yang disesuaikan dengan risiko. Teknik seperti atribusi fitur berbasis SHAP dan protokol penjelasan model diintegrasikan ke dalam dasbor risiko untuk meningkatkan interpretabilitas manusia, aspek tata kelola ini dianalisis secara rinci di Bagian 1.5.

Mekanisme stop-loss dan strategi lindung nilai dinamis semakin didorong oleh sinyal AI. Misalnya, penetapan harga opsi waktu nyata yang berasal dari permukaan volatilitas jaringan saraf memungkinkan penyesuaian yang lebih cepat terhadap eksposur risiko dalam portofolio berbasis derivatif. AI juga mendukung pemantauan intraday dan peringatan prediktif. Peramalan volatilitas intraday menggunakan data frekuensi tinggi dan arsitektur berbasis LSTM berkontribusi pada identifikasi cepat pergerakan harga yang merugikan. Menggabungkan hal ini dengan sinyal mikrostruktur pasar (misalnya, ketidakseimbangan buku pesanan) dapat semakin menyempurnakan strategi eksposur risiko.

Dalam hal personalisasi klien dan perangkat yang sedang berkembang, fungsi inti manajemen aset, teknologi AI mendukung pengembangan strategi investasi yang dipersonalisasi. Sistem rekomendasi menggunakan data perilaku dan demografi untuk menyesuaikan saran investasi dan pemilihan aset dengan profil klien individual. Sistem ini beradaptasi seiring waktu seiring tersedianya data baru, memungkinkan personalisasi berkelanjutan. Selain itu, perangkat AI yang dapat dijelaskan (XAI) digunakan untuk mendukung komunikasi dengan klien, terutama di segmen bernilai tinggi atau institusional.

Laporan yang dipersonalisasi yang menggabungkan keluaran model yang dapat diinterpretasikan (misalnya, kontribusi fitur, analisis sentimen) meningkatkan transparansi dan kepercayaan. Penelitian menunjukkan bahwa keterlibatan klien meningkat ketika pengguna memahami alasan di balik rekomendasi investasi. AI juga berkontribusi dalam memantau profil keberlanjutan portofolio investasi. Teknik untuk penilaian ESG, deteksi kontroversi, dan estimasi paparan risiko iklim semakin terintegrasi ke dalam alur kerja manajemen aset. Misalnya, model NLP digunakan untuk menganalisis pengungkapan perusahaan dan berita

terkait kontroversi, sementara model spasial mendeteksi risiko fisik terkait bahaya lingkungan. Dalam hal ini, aspek metodologis dan tata kelola pemrosesan data ESG dibahas secara komprehensif di Bab 3.

Tabel 2.1 menyajikan ikhtisar tentang bagaimana teknik AI diterapkan di seluruh aktivitas manajemen aset utama, termasuk konstruksi portofolio, alokasi aset, pemantauan risiko, dan personalisasi. Tabel ini juga mencakup fitur-fitur berbasis AI yang umum digunakan dalam layanan robo-advisory. Aplikasi spesifik ini, seperti pemilihan aset otomatis, penyeimbangan ulang, dan rekomendasi yang dipersonalisasi.

**Tabel 2.1.** Aplikasi AI dalam manajemen aset

<b>Aktivitas manajemen aset</b>	<b>Teknik AI yang digunakan</b>	<b>Contoh aplikasi</b>
Konstruksi portofolio	Pembelajaran terawasi (misalnya, hutan acak, jaringan saraf tiruan), pembelajaran tanpa pengawasan (pengelompokan), model hibrida dan ansambel	Prediksi imbal hasil aset, pemeringkatan aset, diversifikasi, identifikasi faktor laten, pemeringkatan berbasis sentimen
Alokasi aset	RL (pembelajaran-Q, DDPG, PPO), jaringan LSTM, GAN, optimasi Bayesian	Alokasi taktis dan strategis, deteksi rezim volatilitas, prakiraan makroekonomi, analisis skenario
Manajemen risiko dan pemantauan kinerja	RNN, LSTM, model Bayesian, SHAP, deteksi anomali, model transformator	Deteksi penyimpangan, peringatan dini, kuantifikasi ketidakpastian, dasbor yang dapat dijelaskan, peringatan intraday
Robo-advisory dan personalisasi	Sistem rekomendasi, AI yang dapat dijelaskan, AI generatif (NLG), model NLP	Saran investasi yang dipersonalisasi, pembuatan laporan, penyaringan ESG, analisis sentimen
Implementasi kelembagaan	Arsitektur modular, API, dan protokol interoperabilitas	Integrasi sistem, penyalarsan penyedia AI pihak ketiga, dan kolaborasi lintas fungsi

Penelitian menekankan perlunya arsitektur AI modular dan Antarmuka Pemrograman Aplikasi (API) yang terstandarisasi — yaitu, protokol terstruktur yang memungkinkan berbagai sistem perangkat lunak untuk berkomunikasi dan bertukar data. API sangat penting untuk memungkinkan integrasi fungsionalitas AI yang aman, efisien, dan fleksibel ke dalam infrastruktur teknologi informasi (TI) yang ada.

Sehubungan dengan adopsi sistem AI oleh institusi ke dalam protokol dan proses manajemen aset, perusahaan dengan cepat melembagakan AI melalui tim ilmu data khusus dan unit strategi AI. Namun, tantangan integrasi tetap ada, termasuk utang teknis, kompleksitas validasi model, dan ketidakpastian regulasi. Protokol tata kelola model internal, yang dibahas di Bagian 1.5, harus mengatasi isu-isu seperti dokumentasi, kewajaran, deteksi bias, dan pelatihan ulang dalam kondisi pasar yang terus berubah.

Lanskap persaingan juga dipengaruhi oleh asimetri dalam adopsi AI. Perusahaan yang lebih besar cenderung mendapatkan keuntungan dari keunggulan skala dalam akses data, daya komputasi, dan akuisisi talenta. Manajer yang lebih kecil mungkin mengandalkan penyedia AI pihak ketiga, sehingga menimbulkan pertanyaan tentang kejelasan dan akuntabilitas, sebagaimana dirinci dalam kerangka regulasi seperti Undang-Undang AI Uni Eropa dan pedoman pengawasan. Selain itu, interoperabilitas antara sistem lama dan platform berbasis AI tetap menjadi hambatan teknis untuk integrasi yang mulus.

Terakhir, pelatihan dan adaptasi budaya tetap menjadi isu inti dalam adopsi organisasi karena penggunaan perangkat AI yang efektif membutuhkan kolaborasi lintas fungsi antara analis keuangan, ilmuwan data, dan petugas kepatuhan. Lembaga yang berinvestasi dalam inisiatif pendidikan dan peningkatan keterampilan AI berada pada posisi yang lebih baik untuk mengelola risiko implementasi dan memastikan keselarasan dengan standar fidusia. Pembahasan spesifik tentang praktik kelembagaan terkait tata kelola model, termasuk auditabilitas dan ekspektasi pengawasan.

### **Robo-advisor dan layanan investasi yang dipersonalisasi**

Robo-advisor merupakan area kunci penerapan AI dalam layanan keuangan, khususnya dalam penyediaan layanan konsultasi investasi yang berbiaya rendah, terukur, dan personal. Sistem ini menggunakan model berbasis algoritma untuk mengotomatiskan alokasi portofolio, profil risiko, dan proses rekomendasi investasi. Awalnya dirancang untuk melayani klien ritel dengan modal investasi terbatas, platform robo-advisor telah berevolusi untuk mendukung model hibrida yang mengintegrasikan pengawasan manusia dan menawarkan layanan yang disesuaikan untuk individu berpenghasilan tinggi dan klien institusional.

Inti dari sistem robo-advisor adalah algoritma yang mengalokasikan portofolio berdasarkan preferensi risiko yang ditentukan pengguna, tujuan investasi, dan horizon waktu. Logika yang mendasarinya biasanya didasarkan pada teori portofolio modern (MPT) atau varian optimasi mean-variance. Namun, sistem yang lebih baru menggabungkan RL, pembaruan Bayesian, dan DL untuk menangkap perilaku pengguna non-linier dan kondisi pasar. Proses onboarding klien mencakup kuesioner otomatis yang dirancang untuk mengumpulkan data demografi, tujuan keuangan, dan toleransi risiko. Algoritma ML yang diawasi mengklasifikasikan pengguna ke dalam kategori risiko dan memetakannya ke strategi investasi yang tepat. Proses pencocokan ini bersifat dinamis, dengan evaluasi ulang masukan pengguna secara berkala untuk menangkap perubahan profil investor. Teknik seperti adaptive boosting dan support vector machines digunakan untuk menyempurnakan segmentasi dari waktu ke waktu.

Robo-advisor terus memantau kinerja portofolio dan memulai rebalancing ketika bobot aset menyimpang dari alokasi target. Algoritma dapat menggabungkan strategi pemanenan rugi pajak, kendala likuiditas, dan prakiraan makroekonomi untuk menginformasikan keputusan perdagangan. Model RL, misalnya, menyesuaikan frekuensi dan ambang batas rebalancing dengan mengoptimalkan fungsi imbalan berdasarkan trade-off biaya historis dan volatilitas.

Beberapa platform juga menggunakan analisis sentimen dan model prediksi pasar untuk mendeteksi pergeseran sentimen investor atau indikator risiko sistemik. Alat-alat ini mengandalkan teknik NLP dan DL untuk mengurai berita keuangan dan umpan media sosial, menawarkan keunggulan dalam mengantisipasi koreksi pasar atau perubahan perilaku. Integrasi teknik data tak terstruktur tersebut dengan data portofolio terstruktur menggambarkan sifat multimoda sistem robo-advisory canggih.

AI memungkinkan personalisasi tingkat tinggi dengan menggabungkan prinsip-prinsip keuangan perilaku ke dalam algoritma advorisi. Sistem dapat mengidentifikasi kecenderungan seperti keengganan terhadap kerugian, terlalu percaya diri, atau inersia, dan menyesuaikan rekomendasi. Misalnya, pengguna yang menunjukkan perilaku menghindari risiko selama penurunan pasar dapat menerima dorongan otomatis untuk menghindari penjualan panik, berdasarkan pola perilaku historis.

Sistem rekomendasi, yang diadopsi dari aplikasi e-commerce, digunakan untuk menyarankan produk keuangan, rencana tabungan, atau dana yang berfokus pada ESG berdasarkan preferensi pengguna dan perilaku rekan sejawat. Sistem ini menggunakan penyaringan kolaboratif, penyaringan berbasis konten, dan pendekatan hibrida untuk meningkatkan keterlibatan dan retensi. Pelaporan investasi yang dipersonalisasi juga telah berkembang melalui perangkat AI yang dapat dijelaskan (XAI), yang menghasilkan wawasan yang mudah digunakan tentang kinerja portofolio, kontribusi aset, dan eksposur risiko. Kemampuan ini meningkatkan transparansi dan kepercayaan tanpa adanya interaksi manusia secara langsung. Untuk pembahasan mendetail tentang kemampuan dijelaskan dalam AI keuangan.

Mengingat sifatnya yang otomatis, robo-advisor tunduk pada persyaratan tata kelola terkait kemampuan dijelaskan, kewajaran, dan pengawasan risiko, dengan otoritas regulasi menekankan perlunya dokumentasi logika algoritma, akurasi profil pengguna, dan auditabilitas keluaran rekomendasi. Mitigasi bias sangat penting dalam sistem yang dipersonalisasi, di mana algoritma dapat mencerminkan ketidaksetaraan historis atau stereotip perilaku. Lembaga didorong untuk menerapkan praktik pembelajaran mesin (ML) yang sadar kewajaran, melakukan audit rutin, dan memvalidasi hasil di seluruh kelompok demografi. Selain itu, model robo-advisory hibrida yang mengintegrasikan tinjauan manusia memerlukan protokol eskalasi dan pelatihan kepatuhan yang terdefinisi dengan baik. Struktur tata kelola harus menggambarkan peran pemilik algoritma, petugas kepatuhan, dan staf teknis. Praktik kelembagaan ini selaras dengan kerangka kerja tata kelola model yang lebih luas.

Adopsi layanan robo-advisory telah dipercepat karena efisiensi biaya, skalabilitas, dan perubahan ekspektasi investor, terutama di kalangan demografi digital-native. Namun, beberapa tantangan masih ada. Tantangan-tantangan ini meliputi kekhawatiran privasi data, keterbatasan dalam menangani produk investasi non-standar, dan kompleksitas integrasi robo-advisor ke dalam infrastruktur perbankan lama.

Robo-advisor semakin banyak ditawarkan melalui model berbasis API yang dapat disematkan ke dalam aplikasi perbankan, platform pensiun, atau alat skrining ESG.

Modularisasi ini dapat memfasilitasi integrasi ekosistem yang lebih luas dan inovasi produk. Untuk integrasi ESG dalam platform robo-advisory dan tantangan data serta metodologi terkait, lihat Bab 3, yang membahas aplikasi AI dalam keuangan berkelanjutan.

Saat ini, lanskap persaingan dibentuk oleh perusahaan rintisan fintech dan lembaga keuangan mapan. Sementara perusahaan rintisan menghadirkan kelincahan, inovasi yang cepat, dan eksperimen teknologi, lembaga yang mapan menawarkan keunggulan dalam pengenalan merek, keakraban dengan regulasi, dan skala operasional. Aliansi strategis, akuisisi, dan kemitraan label putih telah menjadi pendekatan umum untuk memperluas kapabilitas konsultasi digital tanpa perlu mengembangkan platform menyeluruh secara internal. Seiring meluasnya layanan robo-advisory ke bidang-bidang seperti perencanaan pensiun, investasi berdampak, dan optimalisasi pajak, pentingnya tata kelola data yang kuat dan validasi model yang berkelanjutan menjadi semakin nyata.

Kelangsungan hidup model-model ini dalam jangka panjang akan bergantung pada kemampuan untuk menyeimbangkan otomatisasi, personalisasi, dan kepatuhan regulasi secara efektif dalam ekosistem keuangan yang terus berkembang. Khususnya, robo-advisory semakin banyak digunakan melalui konfigurasi berbasis API, memungkinkan integrasi yang mulus ke dalam aplikasi perbankan, platform perencanaan pensiun, dan perangkat skrining ESG. Arsitektur modular ini memfasilitasi kompatibilitas ekosistem yang lebih luas dan mempercepat inovasi produk keuangan.

### **2.3. KECERDASAN BUATAN DALAM STRATEGI PERDAGANGAN DAN OPERASI PASAR**

Sementara aplikasi manajemen aset AI berfokus pada konstruksi strategi investasi dan personalisasi portofolio jangka panjang, strategi perdagangan menuntut pengambilan keputusan berkecepatan tinggi dan adaptasi dinamis terhadap kondisi pasar yang berubah dengan cepat. Bagian ini mengeksplorasi peran AI dalam peramalan intraday, eksekusi order, analisis struktur mikro pasar, dan pengendalian risiko. Bagian ini mencakup integrasi model Pembelajaran Mesin (ML) dan Pembelajaran Mesin (DL) dalam prediksi harga, ekstraksi sinyal, optimasi eksekusi perdagangan, dan fungsi kepatuhan.

Strategi perdagangan berbasis AI sering kali dimulai dengan pembangkitan sinyal prediktif, yang bertujuan untuk meramalkan pergerakan harga aset berdasarkan data historis dan waktu nyata (real-time). Model pembelajaran terawasi seperti SVM, RF, dan metode peningkatan gradien sering dilatih pada indikator teknis, variabel makroekonomi, dan fitur yang berasal dari sentimen untuk memprediksi arah harga atau imbal hasil dalam jangka pendek. Baru-baru ini, pendekatan Pembelajaran Mesin (DL) telah diperkenalkan untuk memodelkan dependensi nonlinier dan mengekstraksi pola laten dari data tidak terstruktur. Misalnya, jaringan saraf tiruan konvolusional (CNN) telah diterapkan pada gambar grafik candlestick dan peta panas buku pesanan untuk mendeteksi pola perdagangan visual.

Model NLP banyak digunakan untuk mengekstrak informasi yang relevan dengan perdagangan dari sumber tekstual yang tidak terstruktur seperti berita keuangan, laporan pendapatan perusahaan, panggilan analis, dan aliran media sosial. Model-model ini mendukung strategi perdagangan jangka pendek dengan mengidentifikasi pergeseran

sentimen, mendeteksi sinyal peristiwa, dan mengantisipasi reaksi pasar terhadap pengumuman dan perkembangan ekonomi makro.

Kemajuan terbaru dalam arsitektur berbasis transformator, seperti BERT (Bidirectional Encoder Representations from Transformers) dan GPT (Generative Pre-trained Transformers), telah secara signifikan meningkatkan kapasitas sistem AI untuk memahami narasi keuangan dan mengekstrak indikator sentimen yang kompleks. Model-model ini dilatih pada korpus besar dan disempurnakan pada set data spesifik domain untuk mengklasifikasikan sentimen, mendeteksi ketidakpastian, dan mengekstrak pemicu yang digerakkan oleh peristiwa dengan presisi tinggi.

Misalnya, model BERT yang disempurnakan dapat mengidentifikasi prospek positif atau negatif dalam panggilan pendapatan, sementara sistem berbasis GPT dapat merangkum konten penggerak pasar utama secara real-time. Untuk meningkatkan kinerja prediktif, fitur-fitur tekstual ini sering kali diintegrasikan dengan data numerik seperti harga saham, indeks volatilitas, dan indikator makroekonomi dalam kerangka kerja pembelajaran multimoda. Penggabungan ini memungkinkan algoritma perdagangan menghasilkan sinyal perdagangan yang lebih responsif dan terinformasi secara kontekstual. Studi empiris telah menunjukkan bahwa pendekatan multimoda mengungguli model sumber tunggal dalam tugas peramalan intraday dan prediksi volatilitas.

Secara paralel, AI semakin banyak diterapkan pada analisis struktur mikro pasar, mekanisme terperinci tentang bagaimana perdagangan dieksekusi di pasar elektronik modern. Ini mencakup pemodelan dinamika buku pesanan, pembaruan kuotasi, spread bid-ask, dan hasil probabilistik dari berbagai jenis pesanan. Model RL sangat cocok untuk domain ini, di mana agen harus belajar berinteraksi dengan lingkungan yang kompleks dan sebagian dapat diamati serta beradaptasi dengan fluktuasi likuiditas dan kedalaman pasar secara real-time.

Teknik DRL, seperti Deep Q-Networks (DQN), Proximal Policy Optimization (PPO), dan metode Actor-Critic, digunakan untuk melatih agen eksekusi yang mengoptimalkan strategi penempatan pesanan di bawah batasan latensi, batasan modal, dan dampak pasar. Agen-agen ini bertujuan untuk memaksimalkan alpha yang terealisasi atau meminimalkan biaya transaksi dengan menyesuaikan penempatan pesanan limit, memilih antara pesanan pasar dan pasif, serta memodifikasi strategi secara dinamis sebagai respons terhadap perubahan kondisi likuiditas. Model-model tersebut mendapatkan manfaat dari pembelajaran berkelanjutan dan sering diterapkan dalam lingkungan perdagangan frekuensi tinggi (HFT). Kerangka kerja pelatihan mereka bergantung pada lingkungan historis dan simulasi, sementara penerapannya memerlukan protokol pemantauan yang ketat untuk memastikan keselarasan dengan tolok ukur kualitas pelaksanaan dan kepatuhan peraturan.

Jaringan LSTM dan model berbasis perhatian semakin banyak digunakan untuk memperkirakan dinamika arus pesanan jangka pendek, ketidakseimbangan kuotasi, dan fluktuasi likuiditas. Arsitektur ini sangat efektif dalam menangkap ketergantungan temporal dan mengidentifikasi pola laten dalam aliran data frekuensi tinggi, seperti pergerakan harga tick-by-tick, snapshot buku pesanan, dan perubahan kedalaman pasar. Keluaran prediktif yang dihasilkan oleh model-model ini diintegrasikan ke dalam sistem perutean pesanan cerdas

(SOR), yang mengalokasikan dan memecah pesanan perdagangan besar di berbagai tempat perdagangan. Sistem ini mengoptimalkan kecepatan eksekusi, meminimalkan slippage, dan efisiensi biaya transaksi.

Di pasar ekuitas yang terfragmentasi, di mana likuiditas tersebar di seluruh bursa dan sistem perdagangan alternatif, algoritma SOR berbasis AI secara dinamis mengevaluasi parameter spesifik tempat, termasuk latensi, panjang antrean, probabilitas pengisian historis, dan struktur biaya. Berdasarkan metrik ini, sistem mengadaptasi strategi eksekusi secara real-time, merutekan porsi perdagangan ke tempat yang menawarkan kondisi paling menguntungkan. Proses ini menggambarkan struktur loop tertutup dari sistem perdagangan algoritmik modern. Dalam arsitektur ini, model peramalan menghasilkan sinyal perdagangan, mesin keputusan menerjemahkannya menjadi instruksi yang dapat dieksekusi, dan umpan balik real-time mengenai kualitas eksekusi, dampak pasar, dan latensi diumpankan kembali ke dalam proses pelatihan ulang model dan logika perutean.

Integrasi iteratif ini meningkatkan kemampuan adaptasi dan responsivitas, terutama dalam kondisi volatilitas tinggi atau likuiditas rendah. Loop ujung ke ujung juga menyoroti pentingnya infrastruktur operasional, termasuk protokol pelatihan ulang model, pemantauan kinerja, dan kerangka kerja tata kelola yang dibahas di Bagian 1.5. Dalam lingkungan perdagangan frekuensi tinggi, AI memainkan peran penting dalam pembangkitan sinyal, manajemen latensi, dan pengendalian risiko intraday. Inti dari strategi HFT adalah kemampuan untuk mengidentifikasi dan memanfaatkan peluang arbitrase yang cepat berlalu, yang seringkali hanya berlangsung beberapa milidetik. Pembangkitan sinyal pada skala ini bergantung pada pendeteksian pola mikro dalam data tick-level, seperti perubahan cepat dalam spread bid-ask, ketidakseimbangan kedalaman order book, dan lonjakan volume.

Pola-pola ini membutuhkan model yang sangat cepat, efisien, dan berlatensi rendah yang dapat memproses sejumlah besar informasi secara real-time. Untuk mendukung tuntutan komputasi ini, teknik pemilihan fitur digunakan untuk mengurangi noise dan dimensionalitas dalam dataset frekuensi tinggi. Metode seperti pemeringkatan informasi mutual, kompresi fitur berbasis autoencoder, dan pemfilteran komponen utama digunakan untuk mengidentifikasi fitur yang paling informatif sekaligus mengurangi redundansi dan membatasi overhead komputasi.

Tujuannya adalah untuk mempertahankan daya prediktif sekaligus memungkinkan eksekusi skala milidetik. Model AI yang diterapkan dalam perdagangan frekuensi tinggi juga harus menjaga netralitas pasar, membatasi paparan terhadap pergerakan pasar yang terarah, dan meminimalkan seleksi yang merugikan, di mana perdagangan dieksekusi tepat sebelum harga bergerak tidak menguntungkan. Untuk mencapai hal ini, model disetel untuk menyeimbangkan agresivitas dan kepasifan agar dapat tunduk, beradaptasi dengan kondisi likuiditas, dan menghindari perilaku yang dapat diprediksi yang dapat dieksploitasi oleh pelaku pasar lainnya.

Agen DRL telah diimplementasikan untuk mengelola inventaris intraday dan agresivitas kuotasi. Agen-agen ini mempelajari kebijakan keputusan optimal melalui interaksi dengan lingkungan perdagangan simulasi atau historis. Misalnya, model DRL menyesuaikan agresivitas

kuotasi, memutuskan apakah akan menempatkan pesanan mendekati atau menjauh dari harga tengah, berdasarkan estimasi waktu nyata kedalaman pasar, spread, dan ketidakseimbangan arus pesanan. Mereka juga mengelola risiko inventaris dengan menggeser intensitas kuotasi beli dan jual secara dinamis untuk mengurangi eksposur terhadap posisi sepihak di bawah ketidakpastian. Implementasi yang lebih canggih mencakup pengaturan RL adversarial, di mana agen perdagangan utama dilatih di hadapan musuh simulasi.

Musuh ini menimbulkan gangguan, guncangan pasar, atau perilaku manipulatif simulasi (seperti spoofing), yang memaksa agen untuk mengembangkan strategi perdagangan yang lebih tangguh dan adaptif. Kerangka kerja adversarial ini sangat berharga dalam lingkungan pasar non-stasioner, di mana model konvensional mungkin gagal untuk digeneralisasi di seluruh rezim yang berubah atau dinamika peristiwa langka. Model AI semakin banyak digunakan dalam strategi perdagangan lintas aset dan multifaktor, dengan tujuan mengidentifikasi sinyal prediktif dari interdependensi, korelasi, dan perubahan struktural yang kompleks di berbagai kelas aset. Strategi ini memanfaatkan kemampuan AI untuk mengungkap hubungan laten, mendeteksi pergeseran rezim, dan memodelkan dinamika lead-lag yang seringkali tidak tertangkap oleh model ekonometrika tradisional.

Algoritma pengelompokan seperti K-means, pengelompokan spasial berbasis kepadatan aplikasi dengan noise (DBSCAN), dan pengelompokan hierarkis digunakan untuk mengelompokkan aset berdasarkan properti statistik yang sama, seperti distribusi imbal hasil atau perilaku volatilitas, yang memfasilitasi perancangan strategi perdagangan berpasangan, arbitrase statistik, dan perdagangan dispersi.

Teknik-teknik ini memungkinkan para pedagang untuk memanfaatkan divergensi harga sementara di antara aset-aset yang secara historis bergerak bersama, dengan asumsi perilaku mean-reverting. Secara khusus ditargetkan untuk mengekstraksi faktor-faktor umum laten dari harga aset, model faktor dinamis seperti analisis komponen utama (PCA), Analisis Komponen Independen (ICA), dan jaringan Bayesian dinamis digunakan. Metode-metode ini mengidentifikasi faktor-faktor tersembunyi yang menjelaskan pergerakan bersama imbal hasil dan pergeseran struktur pasar, sehingga meningkatkan konstruksi strategi dalam kondisi dinamis.

Arsitektur pembelajaran multi-tugas (MTL) memungkinkan sistem AI untuk berbagi parameter di seluruh tugas prediksi terkait, seperti peramalan imbal hasil untuk beberapa aset, sekaligus menangkap aspek-aspek spesifik aset. Pembelajaran bersama ini meningkatkan generalisasi dan memungkinkan pelatihan yang lebih efisien, terutama dalam pengaturan dengan data yang tidak seimbang atau jarang. MTL telah terbukti efektif dalam peramalan multi-aset dan pemodelan risiko lintas-bagian.

Model ensemble juga banyak diimplementasikan untuk mengintegrasikan berbagai sinyal perdagangan. Algoritma seperti RF, GBM, dan arsitektur neural hibrida menggabungkan indikator seperti momentum, valuasi, volatilitas, tren makroekonomi, dan sentimen untuk membentuk sinyal komposit. Sistem ini secara dinamis menyesuaikan bobot sinyal berdasarkan kinerja prediktif atau kondisi rezim pasar terkini. Misalnya, selama periode volatil

atau tidak likuid, model dapat menurunkan bobot sinyal momentum, yang kurang andal dalam lingkungan tersebut, dan meningkatkan pengaruh sinyal fundamental atau mean-reversion.

Dalam kondisi tren yang stabil, pembobotan dapat berbalik. Pembobotan ulang yang sensitif terhadap konteks ini dimungkinkan oleh kemampuan AI untuk melacak penurunan kinerja, pengelompokan volatilitas, dan indikator rezim pasar secara real-time. Lebih lanjut, sistem AI menggabungkan data keuangan terstruktur, seperti riwayat harga dan rasio akuntansi, dengan sumber data alternatif seperti citra satelit, transkrip panggilan pendapatan, sentimen media sosial, dan lalu lintas web.

Kerangka kerja pembelajaran multimoda digunakan untuk mengintegrasikan masukan ini, meningkatkan cakupan prediktif dan ketahanan model perdagangan berbasis faktor. Integrasi data terstruktur dan tidak terstruktur ini memerlukan protokol prapemrosesan yang canggih, termasuk rekayasa fitur, penyelarasan temporal, dan teknik pengurangan derau, untuk menghindari korelasi palsu dan menjaga validitas model.

**Tabel 2.2.** Aplikasi AI dalam strategi perdagangan dan operasi pasar

Area aplikasi	Metode/Alat AI	Deskripsi
<b>Prediksi harga</b>	LSTM, model transformator, pembelajaran ansambel	Memperkirakan harga aset jangka pendek dan intraday menggunakan data historis dan alternatif.
<b>Ekstraksi sinyal</b>	NLP, analisis sentimen, pemodelan topik	Mengekstrak sinyal prediktif dari data terstruktur dan tidak terstruktur, termasuk berita dan media sosial.
<b>Optimalisasi eksekusi perdagangan</b>	RL, DQN, algoritma genetika	Mengoptimalkan perutean pesanan, meminimalkan slippage, dan beradaptasi terhadap dampak pasar secara real-time.
<b>Analisis mikrostruktur pasar</b>	Jaringan saraf tiruan graf (GNN), pembelajaran tanpa pengawasan	Memahami perilaku pasar melalui spread bid-ask, latensi, dan pola volume.
<b>Prediksi aliran pesanan</b>	RNN, mekanisme atensi	Memprediksi dinamika order book dan pergeseran likuiditas dalam hitungan mikrodetik.
<b>Manajemen risiko dalam HFT</b>	Kerangka kerja ModelOps, pemantauan waktu nyata, sistem kill-switch	Mengelola risiko operasional dengan pelatihan ulang otomatis, pemeriksaan kinerja, dan protokol override.
<b>Pengawasan pasar dan deteksi anomali</b>	Algoritma deteksi anomali, autoencoder, hutan isolasi	Mendeteksi pola perdagangan yang tidak teratur untuk kepatuhan regulasi dan pencegahan penipuan.

Uji ulang dan simulasi strategi	GAN, mesin simulasi	Menguji strategi perdagangan dalam lingkungan sintetis untuk menilai ketahanan dan kemampuan adaptasi.
---------------------------------	---------------------	--

AI juga diterapkan untuk memastikan bahwa strategi perdagangan tetap berada dalam parameter risiko yang ditentukan dan mematuhi standar regulasi. Mesin risiko waktu nyata yang didukung oleh AI secara terus-menerus memantau eksposur, leverage, batas penarikan, dan kecukupan modal. Algoritma deteksi anomali menandai perilaku perdagangan yang tidak biasa, yang berpotensi terkait dengan kesalahan operasional, kegagalan sistem, atau pelanggaran pengendalian internal.

Sistem pemantauan kepatuhan mengintegrasikan pengenalan pola dengan NLP untuk melacak perkembangan regulasi, menganalisis komunikasi perdagangan, dan memastikan kepatuhan terhadap aturan perilaku pasar. Sistem ini membantu tim kepatuhan dalam mengidentifikasi perdagangan orang dalam, spoofing, dan manipulasi pasar. Misalnya, model pembelajaran tanpa pengawasan telah digunakan untuk mendeteksi penyimpangan dari pola perdagangan normatif atau anomali komunikasi dalam platform pesan yang digunakan oleh para pedagang.

Keberhasilan penerapan AI dalam perdagangan juga bergantung pada infrastruktur dan skalabilitas. Arsitektur latensi rendah, komputasi tepi (edge computing), dan layanan kolokasi memungkinkan eksekusi yang dekat dengan lokasi pasar. Platform berbasis cloud mendukung pelatihan dan pengujian ulang model kompleks menggunakan data historis tingkat tick, memfasilitasi iterasi dan peningkatan model yang cepat. Perusahaan semakin banyak mengadopsi sistem modular dengan API untuk penerapan model, memastikan kompatibilitas dengan sistem eksekusi lama sekaligus menjaga keamanan dan auditabilitas.

Penerapan teknik pembelajaran penguatan dalam perdagangan kuantitatif membutuhkan infrastruktur yang mampu memastikan stabilitas dan keandalan operasional. Algoritma ini harus beradaptasi secara dinamis terhadap perubahan kondisi pasar sekaligus meminimalkan overfitting dan ketidakstabilan kinerja jangka panjang. Untuk mendukung implementasi model tersebut yang aman dan skalabel dalam lingkungan produksi, adopsi kerangka kerja ModelOps telah diusulkan. Kerangka kerja ini memperluas prinsip-prinsip manajemen siklus hidup perangkat lunak (misalnya, CI/CD) ke seluruh siklus hidup model AI, mengintegrasikan validasi berkelanjutan, pemantauan waktu nyata, dan perlindungan otomatis seperti sistem kill-switch atau mekanisme rollback untuk mengatasi kegagalan atau anomali pasar yang tidak terduga.

Pelatihan ulang model, kontrol versi, dan validasi waktu nyata merupakan komponen inti ModelOps, sebuah kerangka kerja terstruktur untuk mengelola model AI dan pembelajaran mesin di seluruh aplikasi operasionalnya. Di lembaga keuangan, proses ModelOps memastikan bahwa model yang diterapkan dalam produksi dipantau secara berkelanjutan, dilatih ulang ketika kinerja menurun, dan diversi untuk menjaga ketertelusuran dan catatan kepatuhan. Kemampuan operasional ini sangat penting dalam lingkungan perdagangan frekuensi tinggi, di

mana model mengeksekusi volume perdagangan yang besar dalam hitungan milidetik, dan bahkan kesalahan prediksi atau latensi kecil pun dapat mengakibatkan kerugian finansial yang substansial. Untuk memitigasi risiko operasional, lembaga menggabungkan kontrol otomatis seperti mekanisme kill-switch dan sistem peringatan waktu nyata.

Kontrol ini memungkinkan operator manusia untuk mengesampingkan strategi otomatis di bawah ambang batas yang telah ditentukan sebelumnya atau kondisi pasar yang tidak terduga, sehingga memperkuat pengawasan dalam infrastruktur perdagangan yang sangat otomatis. Di tingkat institusional, integrasi AI ke dalam strategi perdagangan sedang membentuk kembali praktik organisasi.

Peran front-office semakin didukung oleh asisten AI yang menyediakan analitik prediktif, overlay sentimen, dan rekomendasi eksekusi order yang optimal. Meja perdagangan berevolusi menjadi lingkungan hibrida di mana manusia dan algoritma beroperasi bersama, dengan struktur pengawasan yang terdefinisi dengan jelas. Penelitian menunjukkan bahwa perusahaan yang mengadopsi AI dalam perdagangan melaporkan peningkatan respons terhadap kondisi pasar dan pengurangan biaya eksekusi. Namun, beban operasional untuk memelihara sistem AI, terutama dalam hal validasi, interpretabilitas, dan kepatuhan, tetap substansial.

Selain itu, maraknya perdagangan berbasis AI menimbulkan pertanyaan tentang perilaku sistemik dan stabilitas pasar. Homogenisasi arsitektur model dan sumber sinyal dapat berkontribusi pada crowding dan herding, yang memperburuk volatilitas selama tekanan pasar. Kekhawatiran ini dibahas dalam Bab 4, yang berfokus pada kompleksitas dan risiko sistemik dalam sistem keuangan berbasis AI.

#### **2.4. KECERDASAN BUATAN UNTUK RISIKO KREDIT DAN INOVASI PENILAIAN**

Manajemen risiko kredit merupakan fungsi inti dalam sistem keuangan, yang dirancang untuk menilai probabilitas gagal bayar peminjam dan memitigasi kerugian di seluruh portofolio pinjaman. Fungsi ini mencakup beberapa fase operasional, termasuk evaluasi kredit awal, penilaian, pemantauan kinerja pinjaman, dan pengendalian eksposur. Secara historis, proses ini mengandalkan model statistik seperti regresi logistik dan linear, yang diterapkan pada sumber data terstruktur seperti dokumentasi pendapatan, utang yang belum dibayar, dan riwayat pembayaran. Meskipun model-model ini memberikan interpretabilitas dan stabilitas statistik, kinerjanya cenderung tidak memadai dalam konteks yang melibatkan nonlinieritas, dimensi tinggi, atau sinyal perilaku alternatif.

Transformasi digital ekosistem keuangan, yang dikombinasikan dengan peningkatan ketersediaan data dari sumber-sumber non-tradisional, telah menantang kecukupan pendekatan tradisional. Dalam konteks ini, AI dan ML telah diadopsi secara progresif karena kemampuannya mendeteksi pola risiko laten, memproses data tak terstruktur, dan memodelkan perilaku peminjam dengan presisi yang lebih tinggi. Inovasi-inovasi ini memengaruhi fase underwriting, dengan meningkatkan keputusan penilaian dan penetapan harga kredit, serta fase pasca-originasinya, dengan memungkinkan deteksi risiko dini dan strategi manajemen risiko adaptif.

Mengingat relevansi sistemik dari penilaian kredit dan praktik peminjaman, penggunaan model AI dalam domain ini memunculkan tanggung jawab kelembagaan yang substansial. Tanggung jawab ini meliputi validasi data, transparansi hasil, praktik tata kelola, dan kepatuhan regulasi. Meskipun tema-tema ini dibahas secara mendalam di Bagian 1.5 dan Bab 4, beberapa referensi terpilih untuk tema-tema tersebut dimasukkan dalam bagian ini jika diperlukan, terutama terkait mitigasi bias, keterjelasan model, dan penyelarasan pengawasan.

### **Rekayasa fitur lanjutan dan integrasi data**

Pemodelan risiko kredit modern berbasis AI secara signifikan memperluas jangkauan sumber data di luar yang secara tradisional digunakan dalam evaluasi kredit. Sementara model lama terutama bergantung pada variabel terstruktur seperti tingkat pendapatan, riwayat pekerjaan, utang yang belum dibayar, dan catatan pembayaran, model kontemporer menggabungkan beragam input heterogen yang lebih luas. Ini termasuk jejak perilaku yang dihasilkan melalui penggunaan perangkat seluler (misalnya, pola panggilan dan SMS, penggunaan aplikasi), aktivitas e-commerce (seperti tingkat pengabaian keranjang belanja, frekuensi pembelian), perilaku pembayaran digital (misalnya, isi ulang dompet seluler, transfer peer-to-peer), respons tes psikometri, konsistensi pembayaran tagihan utilitas, dan interaksi media sosial.

Sumber data alternatif ini sangat berharga bagi klien dengan jumlah nasabah yang sedikit, individu yang tidak memiliki riwayat kredit formal yang memadai, dan semakin banyak digunakan di wilayah dengan infrastruktur perbankan terbatas atau di mana aktivitas ekonomi informal lazim. Integrasi data tersebut memungkinkan lembaga keuangan untuk membangun profil peminjam multidimensi yang menangkap ciri-ciri perilaku seperti konsistensi, keandalan, dan responsivitas terhadap kewajiban keuangan.

Misalnya, evaluasi psikometrik, yang sering digunakan melalui survei seluler, menilai ciri-ciri kognitif, penghindaran risiko, dan literasi keuangan, yang telah ditemukan berkorelasi dengan perilaku pembayaran kembali. Demikian pula, analitik media sosial telah digunakan untuk menilai stabilitas jaringan dan konsistensi sentimen, dengan beberapa platform menggunakan metrik struktur jaringan pertemanan sebagai proksi untuk kepercayaan dan kemungkinan gagal bayar.

NLP memainkan peran yang semakin besar dalam mengekstraksi informasi yang relevan dengan kredit dari data teks yang tidak terstruktur. Catatan tekstual seperti narasi aplikasi pinjaman, keluhan nasabah, transkrip obrolan dengan agen layanan, dan korespondensi tertulis ditambang untuk mendeteksi sinyal-sinyal tekanan finansial, urgensi, atau penghindaran. Penanaman kata seperti Word2Vec dan GloVe mengkodekan kedekatan semantik, yang memungkinkan model memahami hubungan kontekstual dalam teks, sementara analisis sentimen mengkuantifikasi polaritas nada (positif, negatif, netral) sebagai proksi untuk keadaan psikologis dan emosional. Teknik pemodelan topik, termasuk Alokasi Dirichlet Laten (LDA), digunakan untuk mengkategorikan kekhawatiran, niat, atau tema terkait risiko peminjam yang muncul dari masukan kualitatif.

Namun, penggunaan masukan data berdimensi tinggi dan beragam menimbulkan tantangan pemodelan dan interpretabilitas yang signifikan. Untuk mengatasi hal ini, teknik

reduksi dimensionalitas digunakan untuk mengompresi fitur masukan menjadi representasi laten yang mempertahankan varians esensial sekaligus meningkatkan efisiensi komputasi. PCA banyak digunakan untuk mengidentifikasi kombinasi linear variabel yang tidak berkorelasi. Metode nonlinier, seperti autoencoder, arsitektur jaringan saraf yang dilatih untuk merekonstruksi data masukan melalui lapisan internal yang terkompresi, mempelajari transformasi kompleks yang mempertahankan struktur relevan dalam ruang berdimensi tereduksi.

Dalam lingkungan fitur jarang berdimensi tinggi (misalnya, teks tokenisasi), penyisipan tetangga stokastik terdistribusi-t (t-SNE) memfasilitasi visualisasi dan deteksi kluster dengan mempertahankan jarak lokal antar titik, sehingga memungkinkan identifikasi segmen peminjam laten dengan karakteristik risiko yang sama.

Representasi laten ini berfungsi sebagai masukan untuk lapisan prediktif berikutnya, meningkatkan ketertelusuran model dan memfasilitasi tugas klasifikasi atau penilaian hilir. Misalnya, kluster dengan profil perilaku serupa yang diturunkan melalui penyisipan t-SNE atau autoencoder dapat dimasukkan ke dalam model ensemble untuk membedakan paparan risiko di antara pelamar yang sebelumnya tidak dapat dibedakan. Lebih lanjut, teknik-teknik tersebut berkontribusi dalam mengungkap tipologi peminjam yang tersembunyi, mendukung desain produk kredit yang disesuaikan dan strategi segmentasi risiko yang dinamis.

Faktanya, kombinasi integrasi data yang beragam, rekayasa fitur canggih, dan pembelajaran representasional ini meningkatkan granularitas, inklusivitas, dan adaptabilitas sistem penilaian kredit modern, terutama dalam konteks kelangkaan data atau volatilitas tinggi. Namun, lembaga yang mengadopsi pendekatan ini harus memastikan validasi yang ketat, penggunaan data yang etis, dan keselarasan dengan standar kewajaran, sebagaimana dijelaskan di bagian selanjutnya.

### **Model pembelajaran mesin dalam penilaian kredit**

Model pembelajaran mesin terawasi kini banyak digunakan untuk meningkatkan daya prediktif penilaian risiko kredit, terutama ketika metode statistik tradisional, seperti regresi logistik, kesulitan menangkap pola kompleks dalam perilaku peminjam dan indikator keuangan. Algoritma pembelajaran mesin ini sangat mahir dalam mengidentifikasi hubungan nonlinier, interaksi tingkat tinggi, dan pola tidak teratur di seluruh kumpulan data yang besar dan heterogen. Model terawasi yang umum digunakan dalam penilaian kredit meliputi GBM, seperti XGBoost dan LightGBM, SVM, dan jaringan saraf tiruan dalam (DNN), yang bersama-sama menyediakan spektrum kapasitas pemodelan mulai dari yang dapat diinterpretasikan hingga yang sangat ekspresif.

Dalam studi perbandingan yang komprehensif, Lessmann dkk. (2015) mengevaluasi beragam algoritma klasifikasi di berbagai kumpulan data kredit dan menunjukkan bahwa model ansambel berbasis pohon, termasuk hutan acak dan metode penguat, secara konsisten mengungguli model linier tradisional dalam prediksi di luar sampel. Pendekatan ansambel ini unggul dalam mengelola kolinearitas, non-monotonisitas, dan nilai yang hilang, yang semuanya sering terjadi dalam set data kredit dunia nyata.

Model DL, termasuk jaringan saraf tiruan feedforward dan lapisan konvolusional (jika berlaku), semakin banyak digunakan karena kemampuannya untuk melakukan abstraksi fitur hierarkis. Model-model ini membangun representasi multi-lapis yang secara progresif menangkap faktor risiko laten dari data masukan mentah, menawarkan kinerja yang tangguh dalam lingkungan berdimensi tinggi dan tidak terstruktur. Misalnya, DNN telah digunakan untuk menggabungkan data biro kredit tradisional dengan fitur perilaku dan alternatif, yang secara signifikan meningkatkan diskriminasi risiko gagal bayar pada segmen peminjam yang sebelumnya kurang terlayani.

Namun, seiring meningkatnya pengawasan regulasi dan kekhawatiran publik atas transparansi algoritmik, kurangnya interpretabilitas dalam model-model kompleks ini menghadirkan tantangan bagi adopsi institusionalnya yang meluas. Untuk mengatasi hal ini, arsitektur hibrida sedang dikembangkan yang mengintegrasikan komponen yang dapat diinterpretasikan dengan lapisan prediktif yang lebih buram.

Misalnya, sistem berbasis aturan dapat digunakan untuk memfilter atau mengkategorikan masukan sebelum menerapkan pengklasifikasi yang dipelajari mesin. Dengan cara ini, keputusan awal atau segmentasi tetap dapat diaudit, sementara prediksi akhir diuntungkan oleh akurasi yang lebih tinggi dari pembelajar kompleks. Pendekatan berlapis ini mendukung kepatuhan regulasi, terutama dalam kerangka kerja yang mewajibkan justifikasi keputusan kredit kepada pemohon, seperti GDPR Uni Eropa dan Undang-Undang Kesempatan Kredit yang Setara AS.

Lini inovasi yang saling melengkapi dan sedang berkembang melibatkan penerapan teknik RL untuk masalah risiko kredit di mana pengambilan keputusan berurutan dan putaran umpan balik sangat penting. Tidak seperti model klasifikasi statis, kerangka kerja RL mengoptimalkan fungsi imbalan jangka panjang melalui pembelajaran coba-coba dalam lingkungan yang dinamis. Dalam manajemen lini kredit, misalnya, agen RL dilatih untuk menyesuaikan batas kredit peminjam dari waktu ke waktu berdasarkan riwayat pembayaran, pola pemanfaatan, dan sinyal perilaku. Dengan mengamati respons peminjam terhadap ketersediaan kredit, algoritma menyempurnakan strateginya untuk meminimalkan risiko gagal bayar sekaligus memaksimalkan keterlibatan dan profitabilitas pelanggan.

Perkembangan terkini dalam DRL, termasuk algoritma seperti DQN, PPO, dan metode Actor-Critic, telah semakin memperluas kemampuan sistem ini untuk beroperasi di lingkungan berdimensi tinggi yang sebagian dapat diamati. Dalam pengaturan eksperimental, model DRL telah terbukti mengungguli aturan penilaian kredit statis dalam menyesuaikan batas kredit, menyesuaikan suku bunga, atau menandai klien berisiko tinggi untuk peninjauan manual. Model-model ini sangat berharga dalam platform fintech dan pinjaman digital di mana umpan balik real-time dari perilaku peminjam tersedia, memungkinkan perbaikan kebijakan yang berkelanjutan.

Terlepas dari potensinya, model RL juga menimbulkan kekhawatiran terkait stabilitas, konvergensi, dan penggunaan yang etis. Misalnya, tanpa batasan yang tepat, agen RL dapat mengeksploitasi korelasi yang tidak diinginkan yang dapat menyebabkan praktik pinjaman yang diskriminatif atau terlalu agresif. Oleh karena itu, integrasi batasan kewajaran, lapisan

interpretabilitas, dan protokol pemantauan yang kuat semakin dipandang penting untuk penerapan operasional.

### **Sistem Pemantauan Perilaku dan Peringatan Dini**

Selain penyaluran kredit, AI semakin banyak digunakan dalam fase pasca-pencairan untuk mendukung pemantauan berkelanjutan terhadap peminjam, yang memungkinkan lembaga keuangan mendeteksi tanda-tanda awal penurunan kredit dan melakukan intervensi sebelum gagal bayar terjadi. Pergeseran dari penilaian risiko statis ke dinamis ini mencerminkan langkah yang lebih luas menuju manajemen risiko kredit proaktif yang didukung oleh aliran data waktu nyata dan teknik pemodelan adaptif.

Alat pemodelan sekuens seperti jaringan saraf berulang (RNN) dan arsitektur memori jangka pendek panjang (LSTM) banyak digunakan karena kemampuannya untuk menangkap ketergantungan temporal dan dinamika sekuensial dalam perilaku peminjam. Model-model ini memproses data berstempel waktu seperti riwayat pembayaran, frekuensi transaksi, pola arus masuk dan keluar, serta saldo rekening harian untuk memprediksi paparan risiko di masa mendatang. Misalnya, perubahan mendadak dalam pendapatan bulanan atau meningkatnya ketidakteraturan dalam waktu pembayaran dapat menjadi indikator awal tekanan keuangan, yang mungkin gagal diidentifikasi oleh metode penilaian tradisional karena strukturnya yang berbasis snapshot.

Penerapan model LSTM telah terbukti sangat berguna dalam konteks di mana perubahan perilaku berlangsung secara bertahap atau menunjukkan efek yang tertunda. Dalam portofolio kredit konsumen, model-model ini memungkinkan bank untuk menghasilkan lintasan risiko spesifik peminjam, mendukung intervensi seperti penawaran restrukturisasi yang ditargetkan atau pengurangan limit yang dinamis. Dalam pinjaman UKM, pemantauan berkelanjutan terhadap tren arus kas dan siklus persediaan telah meningkatkan deteksi dini hambatan likuiditas, mendorong pemberi pinjaman untuk menyesuaikan eksposur kredit secara proaktif.

Untuk melengkapi prediksi terawasi, metode deteksi anomali tak terawasi semakin banyak digunakan untuk menandai perilaku peminjam yang tidak teratur tanpa bergantung pada variabel hasil yang diberi label. Algoritma seperti hutan isolasi, DBSCAN, dan SVM satu kelas dirancang untuk mengidentifikasi observasi yang menyimpang dari garis dasar perilaku yang telah ditetapkan. Metode-metode ini sangat cocok untuk lingkungan yang dicirikan oleh insiden gagal bayar yang rendah atau profil peminjam baru di mana data historis jarang atau tidak seimbang. Dalam praktiknya, teknik deteksi anomali telah menemukan aplikasi yang berharga di lembaga keuangan mikro dan pembiayaan pembangunan yang beroperasi di pasar-pasar yang belum berkembang. Misalnya, selama periode gangguan lingkungan, seperti kekeringan atau bencana alam, perilaku pembayaran kembali peminjam dapat berubah dengan cara yang tidak terekam secara memadai oleh model statis. Sistem deteksi anomali dapat menandai penyimpangan tersebut sejak dini, memungkinkan lembaga untuk menerapkan strategi mitigasi seperti penangguhan sementara atau pengaturan pembiayaan kembali. Demikian pula, ketidakstabilan politik atau krisis kesehatan masyarakat dapat

menghasilkan diskontinuitas perilaku yang memerlukan kalibrasi ulang profil risiko peminjam secara dinamis, yang dirancang untuk dideteksi oleh model-model ini.

Selain itu, lembaga keuangan mengintegrasikan perangkat-perangkat ini ke dalam sistem peringatan dini (EWS), yang menggabungkan berbagai indikator tingkat peminjam dan portofolio ke dalam dasbor risiko yang dipantau oleh petugas risiko. Sistem ini menghasilkan skor risiko berdasarkan masukan kuantitatif dan anomali turunan, yang memungkinkan respons yang berbeda, mulai dari peringatan otomatis hingga tinjauan yang dipimpin manusia. Beberapa lembaga menggunakan model berjenjang di mana detektor tanpa pengawasan menandai potensi masalah yang kemudian dievaluasi oleh pengklasifikasi terawasi yang terlatih untuk menilai kebutuhan eskalasi. Pendekatan multi-tahap ini meningkatkan ketahanan dan mengurangi positif palsu.

Kemampuan ini sangat relevan dalam konteks lingkungan kredit yang terdigitalisasi dengan cepat, di mana kecepatan dan heterogenitas transaksi meningkatkan kompleksitas pemantauan peminjam. Platform pinjaman digital, khususnya, mengandalkan pemantauan perilaku berbasis AI untuk menentukan harga kredit secara dinamis, mengkalibrasi ulang persyaratan, atau memicu protokol komunikasi peminjam. Misalnya, perusahaan fintech di India dan Kenya menggunakan data transaksi uang seluler untuk memperbarui penilaian risiko kredit secara berkala, yang menjadi dasar pengambilan keputusan pemberian pinjaman dan strategi penagihan.

Secara keseluruhan, integrasi pembelajaran sekuensial dan deteksi anomali ke dalam proses pemantauan kredit dapat memperkuat kapasitas kelembagaan untuk mendeteksi sinyal penurunan kredit sejak dini, mengalokasikan sumber daya pemulihan secara lebih efisien, dan mengurangi kerugian akibat gagal bayar. Perangkat-perangkat ini juga dapat mendukung perlakuan yang lebih adil terhadap peminjam dengan memungkinkan personalisasi strategi pemulihan berbasis data, alih-alih intervensi yang seragam.

#### **Kecerdasan buatan dalam pinjaman alternatif dan berbasis platform**

Platform pinjaman digital, termasuk penyedia layanan peer-to-peer (P2P) dan fintech yang berfokus pada UKM, telah muncul sebagai lingkungan inovasi penting untuk menerapkan AI dalam penilaian risiko kredit. Tidak seperti bank tradisional, platform ini seringkali beroperasi dalam lingkungan yang minim data dan harus membuat keputusan kredit yang cepat dan bervolume tinggi dengan akses terbatas ke laporan keuangan konvensional atau skor biro kredit. Oleh karena itu, platform ini sangat bergantung pada sumber data alternatif dan teknik pembelajaran mesin untuk menghasilkan profil peminjam yang dapat ditindaklanjuti secara real-time.

Untuk mengatasi tantangan ini, model pembelajaran mesin (ML) dirancang untuk memproses input yang heterogen dan seringkali tidak terstruktur seperti transaksi point-of-sale (POS), data faktur digital, riwayat pembelian e-commerce, dan laporan arus kas dari perangkat lunak akuntansi berbasis cloud. Data ini seringkali dilengkapi dengan sinyal perilaku yang diambil dari metadata perangkat, pola pergerakan GPS, dan log penggunaan platform, yang memungkinkan penyusunan profil peminjam dalam hitungan menit setelah pengajuan. Dalam pinjaman UKM, wawasan tambahan dapat diperoleh dari hubungan rantai pasok dan

perilaku pembayaran dalam platform B2B, yang memberikan pemahaman kontekstual tentang siklus likuiditas dan risiko rekanan.

Pemberi pinjaman fintech sering menggunakan kerangka kerja pembelajaran ensemble (misalnya, penumpukan gradien boosting, hutan acak, dan model neural) untuk menggabungkan sinyal dari catatan keuangan terstruktur dengan data alternatif. Model-model ini memungkinkan penilaian kredit probabilistik yang berkembang secara dinamis seiring tersedianya data baru. Misalnya, platform pinjaman P2P dapat memperbarui peringkat risiko dan menyesuaikan batas eksposur seiring perubahan perilaku transaksi peminjam atau hubungan dengan vendor seiring waktu. Di pasar negara berkembang, kapasitas untuk mensintesis sumber data non-tradisional ini terbukti penting dalam menjangkau individu yang kurang memiliki akses perbankan dan usaha mikro dengan riwayat kredit formal yang terbatas.

Area inovasi yang sangat menjanjikan adalah penerapan RL untuk mengoptimalkan aspek dinamis dari kontrak kredit. Agen RL dilatih untuk menyesuaikan parameter pinjaman, seperti frekuensi pembayaran, suku bunga, atau batas kredit, berdasarkan respons dan perilaku pembayaran peminjam. Model-model ini mendefinisikan fungsi imbalan yang menggabungkan kepatuhan pembayaran, keterlibatan pengguna, dan pemanfaatan kredit, yang memungkinkan adaptasi waktu nyata (real-time) untuk meminimalkan risiko sekaligus menjaga kepuasan pelanggan. Berbeda dengan model penetapan harga statis, sistem berbasis RL mempersonalisasi persyaratan kredit di seluruh segmen peminjam dan tingkat risiko, mendukung strategi manajemen portofolio yang lebih inklusif dan tangguh.

Sebagai contoh, platform di India dan Asia Tenggara telah menguji coba kerangka kerja RL yang mengkalibrasi ulang penawaran pinjaman sebagai respons terhadap perilaku penggunaan aplikasi, perbandingan dengan rekan sejawat, dan ketepatan waktu pembayaran. Di Afrika Sub-Sahara, pemberi pinjaman mikro berbasis seluler menggunakan model AI untuk menyimpulkan kelayakan kredit dari pembelian pulsa, riwayat pengiriman uang, dan penggunaan dompet seluler, yang memungkinkan peminjam tanpa catatan perbankan formal untuk mengakses modal kerja jangka pendek. Model-model ini beradaptasi dengan cepat terhadap perubahan sinyal peminjam, mengurangi risiko gagal bayar tanpa harus melakukan pengecualian menyeluruh.

Yang terpenting, sistem kredit berbasis AI ini juga mendukung skalabilitas operasional dengan mengotomatiskan pengambilan keputusan, sehingga mengurangi biaya underwriting dan meningkatkan metrik time-to-cash. Platform menyeluruh yang mengintegrasikan penilaian aplikasi, verifikasi identitas, dan penguraian dokumen melalui NLP semakin umum, terutama di kalangan pemberi pinjaman digital. Platform ini menggunakan pengenalan karakter optik (OCR) dan model NLP untuk mengekstrak data terstruktur dari dokumen yang dipindai seperti pengajuan pajak atau tagihan utilitas, yang berkontribusi pada proses onboarding yang lebih cepat dan profil peminjam yang lebih presisi.

Secara paralel, fungsi manajemen risiko ditingkatkan melalui sistem pembelajaran berkelanjutan yang menggabungkan umpan balik peminjam, tren kinerja portofolio, dan indikator makroekonomi. Mesin penilaian kredit dilatih ulang secara berkala menggunakan data terbaru, yang memungkinkannya merespons pergeseran pasar seperti gangguan

pembayaran akibat pandemi atau guncangan pendapatan akibat inflasi. Beberapa platform telah menerapkan teknik validasi adversarial untuk menilai pergeseran model dan mengkalibrasi ulang ambang batas keputusan, memastikan akurasi model yang berkelanjutan dalam lingkungan yang volatil.

### **Bias, keadilan, dan kewajiban regulasi**

Adopsi AI dalam penilaian kredit menghadirkan kemampuan yang kuat untuk akurasi prediktif, tetapi sekaligus menimbulkan kekhawatiran serius terkait kesetaraan, transparansi, dan keselarasan regulasi. Sumber kekhawatiran utama terletak pada potensi penyebaran bias melalui variabel proksi, fitur yang berkorelasi dengan karakteristik yang dilindungi seperti jenis kelamin, ras, atau tingkat pendapatan tanpa merujuknya secara eksplisit. Risiko ini diperkuat ketika menggunakan data perilaku, transaksional, atau alternatif berdimensi tinggi, terutama dalam arsitektur kompleks seperti pembelajaran mendalam dan model ansambel yang digunakan untuk memprediksi probabilitas gagal bayar (PD) atau kerugian karena gagal bayar (LGD).

Bias sering kali berasal dari ketidaksetaraan historis yang tertanam dalam data pelatihan atau dari akses yang tidak seimbang ke infrastruktur kredit tradisional. Sebagaimana disoroti oleh Bazarbash (2019), ketergantungan pada data keuangan konvensional dapat secara tidak proporsional merugikan pelamar dari kelompok yang kurang terwakili, termasuk pekerja informal atau individu di wilayah yang kurang terlayani. Sebagai respons, lembaga keuangan mengadopsi strategi pembelajaran mesin yang mengutamakan kewajaran di berbagai tahap proses pemodelan: pembobotan ulang sampel dalam pra-pemrosesan, debias adversarial selama pelatihan, dan penyesuaian pasca-pemrosesan berdasarkan paritas output.

Audit kewajaran semakin banyak dilakukan menggunakan metrik seperti dampak disparitas, paritas demografis, peluang yang disamakan, dan kalibrasi. Metrik-metrik ini berperan penting dalam mengungkap pola diskriminatif, terutama dalam konteks pinjaman mikro dan kredit digital, di mana variabel proksi dapat berkorelasi kuat dengan fitur yang dilindungi. Lembaga secara aktif memantau kinerja model di seluruh kelompok demografi dan memisahkan distribusi skor untuk mendeteksi dan memperbaiki hasil yang berbeda.

Persyaratan keterjelasan yang diamanatkan oleh regulasi sangat penting bagi transparansi model. GDPR Uni Eropa, Undang-Undang AI yang akan datang, dan ECOA AS semuanya memberlakukan kewajiban untuk mengungkapkan "informasi yang bermakna" tentang logika dan dampak keputusan otomatis. Sebagai tanggapan, perangkat seperti SHAP dan LIME banyak digunakan untuk menghasilkan penjelasan post-hoc yang mudah dipahami.

Perangkat ini juga mendukung auditabilitas dengan menghubungkan hasil keputusan dengan fitur input, yang memungkinkan lembaga untuk menghasilkan rasional individual yang memenuhi persyaratan pengawasan. Beberapa lembaga telah mengintegrasikan perangkat tersebut ke dalam platform yang berhadapan langsung dengan klien, yang memungkinkan pelamar untuk memvisualisasikan elemen data mana yang paling berkontribusi terhadap penilaian kredit mereka. Mekanisme ini memiliki tujuan ganda: meningkatkan transparansi prosedural dan membantu menumbuhkan kepercayaan klien terhadap sistem algoritmik.

Di luar solusi teknis, keadilan dan kepatuhan regulasi semakin tertanam dalam tata kelola kelembagaan. Perusahaan membentuk komite etik, menunjuk petugas kewajaran, dan melakukan tinjauan kewajaran berkala melalui proses ModelOps khusus. Praktik-praktik ini menandakan pergeseran dari koreksi reaktif menjadi pengawasan proaktif, yang menanamkan keadilan ke dalam tata kelola model.

Terakhir, sistem penilaian kredit yang bias memiliki implikasi tingkat makro. Konvergensi algoritmik antar pemberi pinjaman, jika tidak dikoreksi untuk bias sosial, dapat memperburuk eksklusi sistemik dan memperkuat dinamika risiko prosiklikal. Penelitian memperingatkan bahwa efek tersebut dapat memperkuat ketidakadilan struktural dan meningkatkan kerentanan dalam kondisi stres. Hal ini memperkuat kebutuhan untuk mengevaluasi model algoritmik tidak hanya untuk validitas prediktifnya, tetapi juga untuk konsekuensi distribusional dan eksternalitas sistemiknya.

### **Tata Kelola Kelembagaan dan Manajemen Model**

Tata Kelola Kelembagaan sistem risiko kredit berbasis AI harus berevolusi melampaui praktik validasi model risiko tradisional untuk mengatasi tantangan yang ditimbulkan oleh pembelajaran mesin. Sebagaimana diuraikan sebelumnya di bagian ini, perilaku dinamis model pembelajaran mesin, khususnya sensitivitasnya terhadap pergeseran data, gangguan label, dan putaran umpan balik, memerlukan pemantauan dan kalibrasi ulang kinerja yang berkelanjutan. Tuntutan ini berlaku untuk seluruh spektrum komponen pemodelan risiko kredit, termasuk probabilitas gagal bayar (PD), kerugian jika terjadi gagal bayar (LGD), dan eksposur saat gagal bayar (EAD).

Model PD, yang memperkirakan kemungkinan gagal bayar peminjam dalam jangka waktu tertentu, semakin banyak dikembangkan menggunakan pengklasifikasi kompleks seperti mesin penguat gradien dan jaringan saraf dalam (DNN), yang mengintegrasikan data perilaku dan transaksional.

Model LGD, yang menilai potensi kerugian jika terjadi gagal bayar, dapat melibatkan teknik hibrida yang menggabungkan regresi dengan simulasi skenario, terutama ketika menggabungkan data pemulihan agunan. Model-model ini memerlukan definisi label yang kuat dan analisis sensitivitas skenario. Model EAD, yang memperkirakan kemungkinan eksposur pada saat gagal bayar, seringkali mengandalkan pembelajaran ensemble atau model deret waktu untuk memprediksi pemanfaatan jalur kredit bergulir. Tata kelola model sangat penting di sini untuk menghindari overfitting dan menjaga stabilitas dalam lingkungan pasar yang berfluktuasi.

Untuk mengoperasionalkan model-model ini dalam kerangka kerja yang patuh, lembaga-lembaga memformalkan perangkat dan langkah-langkah tata kelola yang spesifik. Ini mencakup standar dokumentasi, log ketertelusuran, validasi internal independen, dan implementasi perangkat explainability seperti SHAP atau LIME. Sebagaimana dibahas di Bagian sebelumnya, struktur tata kelola ini harus memastikan keselarasan dengan ekspektasi regulator, yang mewajibkan lembaga untuk membentuk komite risiko AI, mendefinisikan struktur kepemilikan model, dan menerapkan protokol eskalasi untuk anomali kewajaran dan kinerja.

Pedoman pengawasan terbaru memperkuat tanggung jawab kelembagaan ini. Otoritas Perbankan Eropa dan Bank Sentral Eropa (ECB) telah menekankan perlunya proporsionalitas, keterjelasan, dan tata kelola data dalam model internal yang menggunakan AI/ML. Otoritas nasional seperti BaFin (Otoritas Pengawas Keuangan Federal Jerman) dan ACPR (Otoritas Pengawasan dan Resolusi Prudential Prancis) menerapkan standar auditabilitas dalam pemodelan kredit. Meskipun kecerdasan buatan dapat secara signifikan meningkatkan proses pengambilan keputusan di sektor perbankan, kecerdasan buatan tidak boleh dianggap sebagai pengganti fondasi etika dan penilaian manusia yang mendasari tata kelola yang bertanggung jawab.

Pendorong internal tanggung jawab sosial perusahaan—seperti budaya etika, akuntabilitas pemangku kepentingan, dan keselarasan misi—tetap penting dalam memastikan bahwa inovasi teknologi dipandu oleh nilai-nilai kemanusiaan dan selaras dengan tujuan sosial dan kelembagaan yang lebih luas. Persyaratan yang muncul ini dibahas lebih mendalam di Bab 4, di mana kerangka regulasi untuk pengawasan AI di lembaga keuangan dipetakan dan dikontekstualisasikan.

Faktanya, pelembagaan tata kelola AI membutuhkan adaptasi organisasi dan budaya. Kolaborasi interdisipliner antara ilmuwan data, spesialis risiko kredit, dan petugas kepatuhan sangat penting untuk memastikan bahwa sistem AI dikembangkan dan dipantau sesuai dengan standar etika dan operasional. Pergeseran ini menandai transformasi dalam cara kelayakan kredit dikonseptualisasikan, dioperasionalkan, dan diawasi dalam lanskap keuangan berbasis AI.

## **2.5. EFISIENSI OPERASIONAL DAN OTOMATISASI DENGAN KECERDASAN BUATAN**

Di lembaga keuangan, otomatisasi proses operasional telah menjadi pendorong utama skalabilitas, akurasi, dan kepatuhan. Penerapan pembelajaran mesin dan sistem berbasis data dalam fungsi administratif inti, termasuk rekonsiliasi, penanganan dokumen, pencegahan penipuan, dan pelaporan, telah meningkatkan produktivitas back-office dan mitigasi kesalahan secara signifikan.

Alur kerja yang padat teks seperti klasifikasi dokumen, ekstraksi formulir, dan analisis kontraktual khususnya diuntungkan oleh teknik NLP. Dengan menerapkan model berbasis transformator yang disesuaikan untuk bahasa keuangan, seperti FinBERT, lembaga menyederhanakan prosedur kenali nasabah Anda (KYC), mengotomatiskan pemeriksaan uji tuntas, dan memastikan kepatuhan terhadap persyaratan anti pencucian uang.

Departemen risiko penipuan semakin bergantung pada sistem deteksi anomali yang mampu belajar dari perilaku transaksi masa lalu. Sistem-sistem ini, yang dibangun di atas model terawasi seperti XGBoost dan hutan acak, menandai urutan pembayaran yang tidak lazim dan mendukung prioritas investigasi, sehingga mengurangi positif palsu dan hambatan operasional dalam penyaringan penipuan.

Kewajiban kepatuhan yang memerlukan agregasi, normalisasi, dan pelaporan data berskala besar di seluruh yurisdiksi juga sedang mengalami transformasi. Badan pengawas menuntut akurasi dan ketepatan waktu yang semakin tinggi, mendorong lembaga untuk

mengotomatiskan pembuatan pengungkapan regulasi, dokumentasi uji stres, dan dasbor risiko internal. Implikasi dari transformasi ini terhadap strategi regulasi dibahas lebih lanjut di Bab 4.

Alur kerja operasional seperti pencairan pinjaman, penyelesaian perdagangan, dan manajemen sengketa kini umumnya dijalankan oleh sistem otomasi proses cerdas. Sistem ini menggabungkan otomasi proses robotik (RPA) dengan pembelajaran mesin untuk mengelola input yang tidak terstruktur, memprioritaskan penanganan pengecualian, dan terus meningkatkan logika eksekusi tugas. Pengalihan fungsi inti ke agen otomatis membutuhkan pengawasan yang kuat. Sebagaimana diuraikan dalam Bagian 1.5, kerangka kerja tata kelola internal harus memastikan akuntabilitas model, pelacakan silsilah data, dan validasi. Integrasi otomatisasi ke dalam infrastruktur penting juga menimbulkan kekhawatiran tentang ketahanan, kemudahan penjelasan, dan implikasi etis dari pemindahan tenaga kerja.

Bukti dari studi kasus terbaru menunjukkan bahwa lembaga yang menerapkan otomatisasi dalam originasi kredit dan onboarding nasabah mencapai pengurangan waktu penyelesaian yang terukur, peningkatan kualitas data, dan tingkat kepuasan nasabah yang lebih tinggi, terutama dalam konteks pinjaman UKM dan perbankan ritel.

## **2.6. KECERDASAN BUATAN DALAM PERAMALAN KEUANGAN DAN PEMODELAN RISIKO**

Peramalan di bidang keuangan secara tradisional berfokus pada prediksi harga aset, volatilitas pasar, atau indikator risiko tingkat perusahaan menggunakan perangkat ekonometrika yang didasarkan pada teori deret waktu. Integrasi metode AI dan ML telah memperluas cakupan prediktif ini dengan memungkinkan model yang beradaptasi dengan nonlinieritas, interaksi fitur berdimensi tinggi, dan pergeseran struktural dalam sistem keuangan. Kemajuan ini telah meningkatkan akurasi peramalan di seluruh indikator tingkat aset, eksposur risiko portofolio, dan kerentanan sistemik.

Aplikasi AI dalam peramalan mencakup berbagai dimensi. Prediksi volatilitas, misalnya, telah beralih dari model heteroskedastisitas kondisional autoregresif tergeneralisasi (GARCH) menuju RNN, LSTM, dan arsitektur berbasis perhatian yang dilatih pada umpan pasar waktu nyata. Metode-metode ini sangat cocok untuk menangkap ketergantungan temporal yang kompleks dan jeda struktural dalam seri keuangan. Di pasar yang sangat volatil atau dalam episode krisis, LSTM telah menunjukkan kinerja yang kuat dalam mengantisipasi fluktuasi harga, terutama ketika dikombinasikan dengan indikator sentimen atau variabel makrofinansial.

Pemodelan risiko juga telah berkembang pesat dengan integrasi teknik pembelajaran mesin (ML) ke dalam kerangka kerja keuangan. Pendekatan tradisional seperti nilai risiko (VaR) dan uji stres berbasis skenario masih banyak digunakan, tetapi seringkali dibatasi oleh asumsi stasioneritas dan stabilitas korelasi historis. Model adaptif berbasis data kini memungkinkan respons yang lebih baik terhadap guncangan asimetris dan pergeseran struktural. Metode pembelajaran ensemble, termasuk hutan acak, GBM, dan pengklasifikasi pohon tambahan, seringkali diterapkan untuk memperkirakan distribusi kerugian bersyarat dalam kondisi makroekonomi yang berubah.

Model-model ini menangkap interaksi kompleks antara variabel-variabel seperti leverage, beta pasar, spread kredit, dan indikator likuiditas, sehingga menawarkan sensitivitas yang lebih tinggi terhadap risiko penurunan. Kemampuannya untuk diperbarui dengan data baru menjadikannya sangat berharga untuk analisis periode stres dan diagnostik portofolio waktu nyata. Salah satu perkembangan penting melibatkan estimasi Expected Shortfall (ES), yang mengukur kerugian rata-rata pada  $\alpha\%$  hasil terburuk dan semakin diadopsi dalam pengaturan regulasi seperti Fundamental Review of the Trading Book (FRTB). Model berbasis pohon dan hutan regresi kuantil telah terbukti efektif dalam memperkirakan ES di berbagai tingkat keyakinan, bahkan ketika data tentang peristiwa ekstrem jarang.

Untuk lebih meningkatkan jangkauan prediktifnya, model-model ini semakin terintegrasi dengan mesin pembangkit skenario, termasuk simulasi Monte Carlo, data sintetis berbasis GAN, atau jalur makroekonomi bootstrap. Hal ini memungkinkan manajer risiko untuk mengeksplorasi eksposur risiko ekor dalam kondisi simulasi seperti stagflasi, guncangan suku bunga, atau disrupsi geopolitik. Pendekatan ini khususnya relevan dalam portofolio multi-aset dan lintas mata uang di mana risiko yang tumpang tindih, seperti volatilitas valuta asing atau penularan kredit, memerlukan pemodelan distribusi gabungan tanpa asumsi parametrik yang ketat. Upaya peramalan juga mengatasi risiko sistemik dan penularan di seluruh jaringan keuangan. Seiring meningkatnya interkoneksi bank, manajer aset, dan lembaga non-bank melalui eksposur derivatif dan rantai pendanaan, model konvensional kurang mampu mengidentifikasi saluran propagasi.

Untuk mengatasi hal ini, para peneliti menggunakan algoritma pembelajaran berbasis jaringan seperti GNN, autoencoder, dan arsitektur berbasis atensi yang belajar dari data keuangan terstruktur dan relasional. Model-model ini mendukung deteksi eksposur tidak langsung, ketergantungan rekanan, dan transmisi guncangan likuiditas. Misalnya, GNN yang dilatih pada matriks liabilitas antarbank telah digunakan untuk meramalkan kegagalan kaskade, sementara autoencoder variasional mendalam telah meningkatkan identifikasi pola pergerakan bersama dan korelasi distres dalam sistem perbankan Eropa. Integrasi data ESG, volatilitas pasar, dan karakteristik eksposur memungkinkan simulasi efek transmisi terkait keberlanjutan.

Di luar perbankan tradisional, teknik-teknik ini berkembang hingga mencakup perusahaan asuransi, dana investasi, dan platform teknologi finansial (fintech), menawarkan representasi yang lebih inklusif tentang kerentanan sistemik. Model berbasis grafik diperbarui secara dinamis dan menyerap informasi baru secara terus-menerus, yang meningkatkan relevansinya untuk pemantauan kebijakan dan sistem peringatan dini dalam kondisi pasar yang tidak stabil.

ML juga diterapkan untuk mendukung peramalan risiko terkait iklim dan ESG. Dengan mengintegrasikan skor ESG tingkat perusahaan, profil emisi, dan pengungkapan keberlanjutan, model berbasis AI memberikan wawasan tentang bagaimana paparan lingkungan atau sosial dapat memengaruhi kelayakan kredit, penyangga likuiditas, atau pengelompokan gagal bayar.

Alat-alat ini semakin banyak digunakan dalam penilaian risiko makroprudensial, terutama dalam skenario transisi hijau. Meskipun fleksibel, model peramalan berbasis AI

menimbulkan kekhawatiran metodologis. Ketidakstasioneran merupakan isu yang signifikan, terutama dalam konteks data keuangan makro atau frekuensi tinggi di mana hubungannya berkembang seiring waktu. Tanpa validasi yang kuat, seperti validasi silang berbasis waktu atau evaluasi rolling window, model berisiko mengalami overfitting terhadap fluktuasi terkini.

Kekhawatiran lain berkaitan dengan kualitas dan ketersediaan label prediktif. Dalam model risiko sistemik, misalnya, peristiwa krisis jarang terjadi, yang menyebabkan data tidak seimbang dan target yang jarang. Demikian pula, indikator risiko iklim seringkali kurang terstandarisasi atau menunjukkan inkonsistensi di seluruh perusahaan. Penyelarasan fitur-target dan rekayasa label sangat penting untuk memastikan keluaran yang andal dan dapat diinterpretasikan. Untuk memenuhi ekspektasi operasional dan regulasi, model-model ini harus menghasilkan hasil yang dapat dipahami. Alat-alat eksplanabilitas seperti nilai SHAP, skor kepentingan fitur, dan simulasi kontrafaktual umumnya digunakan untuk menghubungkan keputusan model dengan input spesifik, seperti leverage, spread credit default swap (CDS), atau faktor-faktor ESG, sehingga meningkatkan akuntabilitas internal dan transparansi eksternal.

Dari perspektif kelembagaan, peramalan keuangan yang didukung oleh AI memerlukan manajemen risiko model yang ketat. Hal ini melibatkan dokumentasi siklus hidup, ketertelusuran skenario, dan kepatuhan terhadap ekspektasi pengawas. Lembaga-lembaga Eropa seperti ECB dan EBA telah menekankan pentingnya ketertelusuran dan auditabilitas ketika model AI digunakan dalam perencanaan modal, penilaian likuiditas, atau strategi pemulihan. Bab 4 akan mengkaji lebih lanjut bagaimana pedoman pengawasan ini membentuk penerapan AI dalam konteks yang sensitif terhadap risiko.

## BAB 3

### KECERDASAN BUATAN DAN INTEGRASI ESG DALAM KEUANGAN

#### 3.1. MENANAMKAN SINYAL ESG DALAM KERANGKA KERJA KEUANGAN BERBASIS DATA

Seiring keuangan berkelanjutan bergerak dari pinggiran ke inti sistem keuangan global, permintaan akan informasi lingkungan, sosial, dan tata kelola (ESG) yang andal, terperinci, dan dapat ditindaklanjuti terus melampaui kapasitas infrastruktur data tradisional. Bab ini membahas titik balik yang krusial: meningkatnya ketegangan antara sentralitas strategis faktor-faktor ESG dan batasan operasional tentang bagaimana faktor-faktor tersebut diukur, diungkapkan, dan diinterpretasikan. Alih-alih memperlakukan data ESG sebagai input tetap, bab ini membingkainya kembali sebagai lapisan kecerdasan keuangan yang dinamis dan terus berkembang, yang secara unik dapat disusun, diperluas, dan dipahami oleh AI dan ML.

Dengan berfokus pada bagaimana sinyal ESG dapat diekstraksi, diprediksi, dan diintegrasikan ke dalam alur kerja keuangan, bab ini menyelidiki kapasitas AI untuk menjembatani kesenjangan struktural, seperti divergensi peringkat, materialitas sektoral, dan kurangnya representasi UKM, serta memungkinkan bentuk-bentuk baru konstruksi portofolio berkelanjutan, evaluasi risiko, dan dukungan keputusan waktu nyata. Yang terpenting, bab ini tidak hanya mengkaji kecanggihan teknis model AI, tetapi juga implikasinya terhadap transparansi, inklusivitas, dan pandangan ke depan strategis dalam integrasi ESG.

Dalam konteks ini, bab ini menempatkan AI sebagai mediator informasi keberlanjutan sekaligus agen aktif dalam membentuk kembali bagaimana keberlanjutan dioperasionalkan dalam keuangan, melampaui skor statis, menuju arsitektur pengambilan keputusan yang lebih adaptif dan berbasis bukti.

#### 3.2. PERAN KECERDASAN BUATAN DAN PEMBELAJARAN MESIN

Keuangan berkelanjutan merupakan pendekatan yang terus berkembang untuk mengintegrasikan faktor-faktor ESG ke dalam pengambilan keputusan keuangan, yang bertujuan untuk menyelaraskan tujuan keuangan dengan tujuan sosial dan lingkungan yang lebih luas. Pendekatan ini mencerminkan meningkatnya kesadaran di kalangan investor, regulator, dan pelaku korporat bahwa risiko dan peluang keberlanjutan secara material memengaruhi kinerja keuangan jangka panjang dan ketahanan sistemik.

Peringkat ESG merupakan metrik operasional dominan yang diadopsi di pasar keuangan untuk mengevaluasi kinerja keberlanjutan perusahaan. Namun, tidak seperti peringkat kredit, yang biasanya menunjukkan konvergensi yang kuat di antara para penyedia, peringkat ESG menunjukkan korelasi yang rendah di antara lembaga pemeringkat, sebuah fenomena yang telah diberi label sebagai "kebingungan agregat". Divergensi ini mencerminkan perbedaan mendasar dalam cakupan, pengukuran, dan pembobotan, alih-alih gangguan acak. Hal ini mempersulit konstruksi portofolio dan evaluasi kinerja dengan membuat penilaian ESG sensitif terhadap pilihan penyedia data.

Setiap pilar ESG memperkenalkan serangkaian asumsi dan tantangan metodologisnya sendiri. Pilar Lingkungan (E) biasanya mencakup metrik yang terkait dengan emisi karbon, efisiensi sumber daya, penggunaan energi, konsumsi air, dan paparan terhadap risiko terkait iklim. Variabel-variabel ini seringkali didukung oleh data yang relatif terukur dan terverifikasi, terutama bagi perusahaan besar yang berada di bawah tekanan regulasi untuk mengungkapkan dampak terkait iklim. Pilar Sosial (S), di sisi lain, mencakup faktor-faktor yang kurang nyata dan lebih bergantung pada konteks seperti praktik ketenagakerjaan, hak-hak karyawan, keberagaman dan inklusi, kepatuhan terhadap hak asasi manusia, dan keterlibatan masyarakat.

Elemen-elemen ini sulit distandarisasi dan diukur, terutama di berbagai yurisdiksi hukum dan norma budaya. Demikian pula, pilar Tata Kelola (G) mencakup isu-isu seperti independensi dewan direksi, kompensasi eksekutif, hak-hak pemegang saham, dan kebijakan antikorupsi, domain-domain di mana kualitas pengungkapan dan kerangka kerja kelembagaan sangat bervariasi.

Oleh karena itu, perbedaan dalam peringkat ESG umumnya lebih menonjol pada dimensi S dan G, di mana penerjemahan fenomena kualitatif ke dalam metrik kuantitatif menimbulkan tantangan metodologis yang signifikan. Studi telah menunjukkan bahwa meskipun data lingkungan cenderung lebih terstruktur dan tunduk pada pengawasan regulasi yang lebih ketat, penilaian tanggung jawab sosial dan tata kelola perusahaan seringkali dipengaruhi oleh interpretasi subjektif dan keterbatasan komparabilitas pengungkapan. Perbedaan tersebut telah menuai kritik dari para akademisi dan praktisi yang mempertanyakan kredibilitas dan keandalan peringkat ESG.

Kekhawatiran tersebut mencakup potensi greenwashing, manipulasi pengungkapan strategis, dan kesalahan arah investor akibat inkonsistensi dalam penilaian ESG. Terlepas dari keterbatasan ini, peringkat ESG tetap menjadi tolok ukur yang paling dikenal luas untuk mengintegrasikan keberlanjutan ke dalam keputusan keuangan. Keunggulannya berasal dari kurangnya alternatif yang sama komprehensifnya dan penerapannya dalam inisiatif regulasi, mandat portofolio, dan taksonomi keuangan berkelanjutan.

Kerangka kerja regulasi saat ini, seperti Arahan Pelaporan Keberlanjutan Perusahaan Uni Eropa (CSRD), berfokus terutama pada perusahaan tercatat, sehingga sebagian besar UKM tidak memiliki evaluasi ESG yang terstandarisasi. Asimetri regulasi ini menghadirkan tantangan sekaligus peluang. Di satu sisi, hal ini berisiko menciptakan titik buta informasi dalam upaya integrasi ESG. Di sisi lain, hal ini membuka ruang bagi metodologi berbasis AI untuk menyediakan perluasan analitis yang bermakna. Metodologi ini bertujuan untuk:

- Memperkirakan peringkat atau proksi ESG untuk perusahaan yang tidak tercakup dalam sistem pemeringkatan yang ada menggunakan data yang tersedia untuk umum;
- Mendeteksi hubungan laten antara dimensi ESG, kinerja keuangan, dan risiko spesifik perusahaan atau sistemik;
- Mengidentifikasi dimensi yang sensitif terhadap ESG dan paparan spesifik sektor yang mungkin terlewatkan dalam kerangka kerja terstandarisasi. Teknik AI dan ML dapat memainkan peran yang semakin luas, menawarkan perangkat yang mampu

memproses data ESG yang kompleks dan heterogen, serta memungkinkan pengambilan keputusan investasi yang lebih terinformasi, adaptif, dan berbasis bukti. Integrasi pertimbangan ESG ke dalam analisis keuangan memang didukung oleh bukti empiris yang menunjukkan bahwa perusahaan dengan praktik keberlanjutan yang lebih kuat sering dikaitkan dengan profil risiko yang lebih rendah dan ketahanan yang lebih baik selama kondisi pasar yang buruk

Kemampuan analitis model AI menawarkan perangkat yang menjanjikan untuk mengurangi asimetri informasi dan memperluas cakupan integrasi ESG. Misalnya, algoritma pembelajaran terawasi dapat dilatih pada kumpulan data ESG berlabel untuk menghasilkan skor prediktif bagi perusahaan yang tidak diperingkat, sementara teknik pengelompokan dan pengurangan dimensionalitas dapat mengungkap struktur tersembunyi dalam hubungan ESG-kinerja-risiko. Secara khusus, metode AI yang dapat dijelaskan (XAI) seperti SHAP dan LIME memungkinkan dekonstruksi keluaran model yang kompleks, menyediakan jalur yang dapat diinterpretasikan dari variabel masukan ke prediksi, sebuah fitur penting untuk aplikasi yang sensitif terhadap ESG di mana transparansi dan akuntabilitas tidak dapat dinegosiasikan.

Kapasitas untuk memodelkan pola-pola terkait ESG ini menawarkan manfaat yang signifikan, seperti identifikasi pendorong ESG spesifik konteks terhadap kinerja keuangan dan operasionalisasi metrik ESG alternatif yang melampaui skor spesifik vendor. Lebih lanjut, AI memungkinkan pembaruan dinamis penilaian ESG berdasarkan arus informasi baru, termasuk data tidak terstruktur dari laporan keberlanjutan, media, dan pengungkapan regulasi.

Model-model ini juga dapat mendukung estimasi peringkat ESG untuk UKM dan perusahaan di pasar yang kurang teregulasi, sehingga meningkatkan inklusivitas dan adaptabilitas strategi investasi berkelanjutan. Meskipun replikasi dan efek keuangan jangka panjang masih menjadi pertanyaan empiris yang terbuka, terutama di seluruh yurisdiksi dan siklus ekonomi, pendekatan berbasis AI menawarkan kerangka kerja yang berlandaskan teknis untuk mengoperasionalkan integrasi ESG di luar batasan peringkat yang ada.

### **3.3. METRIK ESG DALAM PENYARINGAN DAN EVALUASI PORTOFOLIO**

Penyaringan portofolio berdasarkan metrik keberlanjutan telah menjadi praktik mendasar dalam keuangan berkelanjutan, yang bertujuan untuk menyelaraskan pilihan investasi dengan kriteria ESG. Secara tradisional dibingkai dalam pendekatan penyaringan negatif dan positif, dengan mengecualikan atau memasukkan aset berdasarkan ambang batas ESG yang telah ditentukan, proses ini semakin dibentuk oleh kemajuan dalam AI dan ML, yang memungkinkan evaluasi yang lebih terperinci, dinamis, dan multidimensi.

Model AI, terutama algoritma pembelajaran terawasi, menawarkan solusi yang terukur untuk meningkatkan presisi penyaringan ESG dengan memprediksi skor ESG atau indikator proksi menggunakan data yang tersedia untuk umum. Model-model ini dapat menggabungkan informasi keuangan terstruktur (misalnya, rasio neraca, belanja modal, leverage, dan profitabilitas), metrik khusus sektor, dan data tekstual tidak terstruktur (misalnya, pengungkapan keberlanjutan, laporan media).

Masukan heterogen tersebut mencerminkan sifat sinyal ESG yang kompleks dan multidimensi, memungkinkan representasi praktik keberlanjutan perusahaan yang lebih holistik. Integrasi ini memungkinkan strategi penyaringan dinamis yang beradaptasi dengan risiko yang muncul dan menggabungkan aliran data waktu nyata.

Misalnya, metode ensemble seperti hutan acak atau mesin penguat gradien telah berhasil dilatih pada kumpulan data ESG berlabel untuk memeringkat perusahaan berdasarkan karakteristik keberlanjutannya. Model-model ini menggabungkan interpretabilitas dengan ketahanan dan sangat cocok untuk menangkap interaksi non-linier antara variabel keuangan dan variabel terkait ESG. Studi terbaru menyoroti kemampuan model-model ini untuk memperkirakan skor ESG dengan akurasi prediktif yang tinggi menggunakan masukan seperti belanja modal terhadap ekuitas, paparan litigasi lingkungan, atau komposisi dewan direksi. Skor prediktif ini dapat menggantikan atau melengkapi peringkat ESG pihak ketiga dalam keputusan penyaringan, terutama untuk perusahaan yang tidak diperingkat, berlokasi di pasar yang kurang teregulasi, atau beroperasi di lingkungan yang minim data.

Model-model ini juga dapat disesuaikan dengan tolok ukur sektoral dengan memasukkan indikator sektor kategoris atau menginteraksikan faktor-faktor ESG dengan klasifikasi industri. Penyesuaian ini memperhitungkan fakta bahwa materialitas ESG sangat bergantung pada konteks: faktor lingkungan lebih relevan dalam energi dan ekstraktif, indikator sosial berperan sentral dalam manufaktur padat karya, sementara tata kelola mendominasi dalam jasa keuangan. Dengan memanfaatkan segmentasi sektoral, sistem penyaringan berbasis AI dapat lebih selaras dengan isu-isu keberlanjutan yang material secara finansial.

Teknik pembelajaran tanpa pengawasan (*unsupervised learning*) semakin memperluas cakupan analitis penyaringan ESG. Algoritma seperti *k-means* dan *DBSCAN* memungkinkan pengelompokan perusahaan ke dalam klaster yang relevan dengan ESG, mengidentifikasi pola bersama di seluruh praktik keberlanjutan dan profil risiko. Klaster ini berfungsi sebagai dasar bagi strategi penyaringan tematik atau sektoral, yang memandu penyusunan portofolio yang terkonsentrasi di domain seperti energi terbarukan, keadilan sosial, atau inovasi tata kelola. Metode reduksi dimensionalitas, termasuk *PCA* dan *t-SNE*, membantu mengungkap dimensi ESG laten yang menjelaskan varians dalam profil keberlanjutan di berbagai perusahaan. Wawasan ini mendukung pemahaman yang lebih rinci tentang posisi ESG dan memungkinkan investor untuk menyempurnakan ambang batas penyaringan.

NLP semakin meningkatkan penyaringan ESG dengan mengekstraksi sinyal waktu nyata (*real-time*) dari data tekstual tak terstruktur, termasuk pengumuman perusahaan, liputan media, dan pengajuan peraturan. Teknik analisis sentimen dan pemodelan topik memungkinkan identifikasi kontroversi atau peluang baru yang relevan dengan ESG, seperti perselisihan ketenagakerjaan, kecelakaan lingkungan, atau inisiatif inovasi sosial, yang mungkin belum tercermin dalam peringkat statis. Metode-metode ini memungkinkan peralihan dari pembaruan ESG berkala ke penyaringan berkelanjutan yang diinformasikan oleh sinyal-sinyal berbasis peristiwa.

Penggabungan sumber data alternatif, seperti citra satelit atau analisis geospasial, merupakan aplikasi baru lainnya. Data ini dapat diproses menggunakan CNN untuk memantau penggunaan lahan, peristiwa polusi, atau pembangunan infrastruktur secara hampir seketika (real-time). Misalnya, model yang dilatih pada data satelit telah digunakan untuk memperkirakan metrik dampak lingkungan tingkat perusahaan, seperti intensitas karbon atau paparan deforestasi, yang meningkatkan penyaringan lingkungan melampaui informasi yang diungkapkan sendiri.

**Tabel 3.1.** Aplikasi AI dalam penyaringan portofolio ESG

Fungsi	Metodologi AI	Aplikasi utama	Keunggulan	Keterbatasan
Penilaian prediktif untuk perusahaan yang tidak diperingkat	Pembelajaran terawasi (misalnya, hutan acak, peningkatan gradien)	Memperkirakan proksi ESG menggunakan data terstruktur dan tekstual	Akurasi tinggi, mudah beradaptasi dengan ketersediaan data, cocok untuk UKM	Tergantung pada kualitas data pelatihan, interpretabilitas bervariasi
Penyaringan khusus sektor	Istilah interaksi dalam model ML dengan klasifikasi industri	Relevansi ESG yang disesuaikan dengan sektor (misalnya, E untuk energi, G untuk keuangan)	Penyelarasan yang lebih baik dengan materialitas; meningkatkan daya banding	Memerlukan keahlian industri dan data pelatihan berlabel
Penyaringan berbasis tematik atau pola	Pengelompokan (K-means, DBSCAN)	Mengelompokkan perusahaan berdasarkan perilaku ESG, memungkinkan portofolio tematik	Mengungkapkan struktur laten, mendukung diversifikasi	Makna kluster bisa jadi tidak jelas; sensitivitas parameter
Deteksi pendorong ESG laten	Reduksi dimensionalitas (PCA, t-SNE)	Mengidentifikasi komponen ESG utama di seluruh perusahaan	Menyederhanakan interpretasi, mengurangi noise	Potensi penyederhanaan konstruksi ESG yang berlebihan
Penyaringan berbasis peristiwa dan waktu nyata	NLP (analisis sentimen, pemodelan topik)	Pembaruan dinamis dari berita, pengungkapan, dan pengajuan	Wawasan real-time, deteksi kontroversi	Bias bahasa/model dapat menyebabkan penyederhanaan
Pemantauan lingkungan di luar pengungkapan	Citra satelit dengan CNN	Melacak polusi, penggunaan lahan, dan perubahan infrastruktur	Verifikasi independen atas dampak lingkungan	Persyaratan teknis dan akses data yang tinggi
Interpretabilitas keputusan penyaringan	SHAP, LIME	Menjelaskan keluaran model	Mendukung transparansi dan kepatuhan regulasi	Penjelasan bersifat perkiraan, tidak selalu intuitif

		dan bobot faktor ESG		
--	--	----------------------	--	--

Alat-alat explainability seperti SHapley Additive exPlanations (SHAP) dan LIME sangat penting dalam aplikasi ESG, di mana transparansi dan akuntabilitas sangat penting. Alat-alat ini menguraikan keluaran model AI, mengidentifikasi variabel mana yang paling memengaruhi keputusan penyaringan. Misalnya, nilai SHAP dapat menyoroti apakah denda lingkungan atau metrik keragaman dewan direksi mendorong pengecualian perusahaan dari portofolio yang disaring ESG. Kemampuan tersebut sangat berharga untuk pelaporan regulasi dan komunikasi investor dalam kerangka kerja seperti Peraturan Pengungkapan Keuangan Berkelanjutan (SFDR) Uni Eropa.

Sistem penyaringan ESG yang didukung AI juga memfasilitasi konstruksi portofolio yang personal dan dinamis. Investor dapat mengungkapkan preferensi mengenai tema-tema ESG tertentu, seperti dekarbonisasi, keanekaragaman hayati, atau etika perusahaan, dan alat-alat AI dapat mengoperasionalkan kendala-kendala ini melalui simulasi dan optimasi. Kemampuan untuk menyusun strategi investasi ESG yang dipersonalisasi dalam skala besar, terutama melalui platform robo-advisory, memperluas partisipasi dalam keuangan berkelanjutan dan memungkinkan investor ritel untuk menerapkan kriteria ESG berdasarkan nilai dan selera risiko mereka. Tabel 3.1 memberikan gambaran umum tentang aplikasi AI yang dibahas dalam penyaringan portofolio ESG.

### 3.4. FAKTOR-FAKTOR ESG DAN PENILAIAN KINERJA

Penilaian faktor-faktor ESG terkait kinerja keuangan telah menjadi pilar utama strategi investasi berkelanjutan. Investor semakin berkomitmen untuk mengevaluasi tidak hanya apakah portofolio selaras dengan tujuan keberlanjutan normatif, tetapi juga bagaimana karakteristik ESG membentuk hasil keuangan. Tujuan ganda, keselarasan etika, dan kinerja keuangan ini telah memicu semakin banyaknya literatur yang menyelidiki peran dimensi ESG dalam mitigasi risiko, peningkatan imbal hasil, dan stabilitas valuasi di berbagai sektor dan horizon waktu.

Temuan penting dalam hal ini adalah bahwa faktor-faktor ESG berbeda dalam relevansi materialnya. Elemen E, S, dan G memberikan dampak yang berbeda pada profil risiko tingkat perusahaan, tergantung pada karakteristik industri, model bisnis, dan rezim regulasi regional. Misalnya, intensitas karbon dan kepatuhan lingkungan mungkin relevan di sektor-sektor yang padat energi, sementara praktik ketenagakerjaan sosial mendominasi di sektor ritel dan manufaktur, dan ketahanan tata kelola khususnya penting dalam jasa keuangan. Heterogenitas ini menyiratkan bahwa metrik ESG yang seragam seringkali tidak memadai untuk evaluasi kinerja. Sebaliknya, model yang disesuaikan sektor diperlukan untuk menginterpretasikan bagaimana praktik ESG diterjemahkan menjadi hasil keuangan.

Model AI, khususnya teknik pembelajaran terawasi, mendukung pergeseran analitis ini dengan mengungkap hubungan nonlinier yang kompleks antara indikator ESG dan metrik kinerja seperti volatilitas, sebaran kredit, atau beta bersyarat. Penelitian dalam domain ini

dikembangkan menggunakan model pembelajaran mesin yang disempurnakan dengan analisis berbasis SHAP untuk menunjukkan bahwa variabel S dan G secara substansial memengaruhi penurunan beta pasar dalam industri yang padat pengetahuan, sementara variabel E menunjukkan dampak marginal yang terbatas di sektor-sektor tersebut dalam jangka pendek.

Kapasitas untuk pemodelan disagregasi dan interaksi ini menunjukkan kontribusi signifikan AI terhadap evaluasi ESG. Meskipun model ekonometrik tradisional seringkali memerlukan asumsi linear dan dibatasi oleh multikolinearitas, metode AI dapat memproses data berdimensi tinggi untuk mengungkap faktor-faktor laten yang memengaruhi ketahanan finansial. Regresor hutan acak dan mesin penguat gradien telah diterapkan untuk mengidentifikasi variabel ESG yang memprediksi volatilitas imbal hasil saham atau risiko spesifik perusahaan, yang seringkali menyoroti interaksi antara kualitas tata kelola dan stabilitas laba sebagai hal yang relevan dengan kinerja jangka panjang.

Riset empiris mendukung relevansi ESG dalam memitigasi risiko penurunan. Perusahaan dengan ESG tinggi mengalami volatilitas yang lebih rendah selama guncangan COVID-19, yang mendukung proposisi bahwa karakteristik ESG menawarkan semacam asuransi implisit selama periode dislokasi pasar. Kualitas tata kelola berkorelasi negatif dengan risiko kredit, sehingga mengurangi kemungkinan terjadinya peristiwa kredit yang merugikan.

Kekuatan AI lainnya dalam penilaian kinerja terletak pada kemampuannya untuk menyesuaikan diri secara dinamis dengan aliran data baru. Teknik NLP memungkinkan integrasi berkelanjutan informasi relevan ESG yang tidak terstruktur, seperti sentimen media, tindakan regulasi, atau laporan lembaga swadaya masyarakat (LSM). Alat-alat ini dapat melengkapi pengungkapan ESG yang tertunda dengan memberikan pembaruan waktu nyata (real-time) mengenai peristiwa reputasi atau risiko yang muncul, sehingga memungkinkan investor untuk mengkalibrasi ulang eksposur mereka berdasarkan perkembangan terkini.

AI memungkinkan penggabungan faktor-faktor ESG ke dalam model keuangan berwawasan ke depan. Simulasi dinamis dan analisis skenario dapat mengkuantifikasi dampak karakteristik ESG terhadap imbal hasil yang diharapkan, respons terhadap tekanan, dan premi risiko di seluruh kelas aset. Landasan teoretis untuk integrasi ini disediakan oleh model yang menunjukkan bahwa preferensi investor terhadap ESG menciptakan pergeseran struktural dalam penetapan harga aset. Model AI yang dilatih pada data panel multi-tahun sangat cocok untuk memperkirakan bagaimana faktor-faktor ESG mendorong eksposur yang bervariasi seiring waktu dan perbedaan valuasi.

Divergensi peringkat di antara penyedia ESG masih menjadi tantangan yang terus berlanjut. Perbedaan skor ESG mencerminkan perbedaan dalam cakupan, pengukuran, dan pembobotan, yang tidak hanya disebabkan oleh variasi acak. Masalah ini telah didokumentasikan secara luas dalam studi perbandingan ESG dan peringkat kredit, yang menunjukkan bahwa meskipun peringkat kredit cenderung konvergen di berbagai lembaga, peringkat ESG berbeda karena tidak adanya kerangka kerja standar dan pedoman pengungkapan yang jelas. Akibatnya, evaluasi kinerja menjadi sangat sensitif terhadap pilihan penyedia data, sehingga mempersulit replikasi empiris dan perbandingan portofolio. Model

berbasis AI menawarkan solusi parsial dengan menyelaraskan masukan ini dan menghasilkan skor komposit melalui pembelajaran ansambel atau konsensus.

Estimasi implikasi kinerja juga harus memperhitungkan horizon waktu. Korelasi jangka pendek antara ESG dan imbal hasil keuangan mungkin lemah atau tidak stabil, sementara efek jangka menengah dan panjang seringkali nonlinier dan bergantung pada guncangan eksternal, seperti perubahan regulasi atau pergeseran preferensi pemangku kepentingan. Komplikasi lebih lanjut adalah sifat data ESG itu sendiri: untuk perusahaan tercatat, seri ESG historis cenderung relatif pendek, terfragmentasi, dan diperbarui setiap tahun. Karakteristik ini membatasi kekuatan statistik model inferensi linear tradisional, terutama ketika jumlah observasi deret waktu tidak mencukupi.

Dalam konteks ini, teknik AI dan ML menyediakan alternatif yang efektif. Banyak model AI, termasuk algoritma pembelajaran terawasi dan metode ensemble, dapat dilatih pada kumpulan data dengan kedalaman temporal terbatas, mengompensasi kelangkaan data dengan menggabungkan heterogenitas lintas bagian dan fitur sintesis. Pendekatan pembelajaran mendalam dan pembelajaran penguatan dapat memperluas ruang fitur lebih lanjut dengan menggabungkan sumber data alternatif, seperti pengungkapan tekstual dan indikator sentimen, yang menawarkan basis prediksi yang lebih luas dan lebih fleksibel. Strategi validasi silang deret waktu dan rolling window meningkatkan ketahanan model dalam menghadapi non-stasioneritas dan memungkinkan adaptasi berkelanjutan terhadap dinamika ESG-keuangan yang berubah. Temuan ini menunjukkan bahwa penilaian kinerja ESG berbasis AI meningkatkan cakupan analitis, spesifisitas sektoral, dan adaptabilitas temporal dari analisis investasi yang terintegrasi dengan keberlanjutan. Dengan memanfaatkan kapasitas pembelajaran mesin untuk deteksi pola dan fusi data, model-model ini melengkapi pendekatan atribusi tradisional dan memberikan gambaran yang lebih mendalam tentang hubungan ESG-keuangan.

### **3.5. TANTANGAN DATA ESG DAN PERMINTAAN PASAR**

Meningkatnya relevansi pertimbangan ESG di pasar keuangan telah meningkatkan pentingnya kualitas, ketersediaan, dan standardisasi data. Namun, terlepas dari upaya regulasi dan kelembagaan yang signifikan, data ESG tetap terfragmentasi, heterogen, dan dalam banyak kasus, tidak terstandardisasi. Hal ini menghadirkan tantangan yang terus-menerus terhadap integrasi yang efektif ke dalam analisis keuangan, konstruksi portofolio, dan pemodelan risiko.

Kesulitan utama terletak pada inkonsistensi pengungkapan ESG di seluruh perusahaan dan yurisdiksi. Meskipun kerangka regulasi seperti mandat CSRD Uni Eropa meningkatkan transparansi ESG bagi perusahaan yang terdaftar, segmen pasar yang besar, termasuk UKM, masih berada di luar cakupan pelaporan ESG wajib. Asimetri regulasi ini menciptakan kesenjangan informasi dan bias dalam cakupan data, yang membatasi penerapan analisis ESG di seluruh dunia investasi yang lebih luas.

Asimetri ini diperparah oleh disparitas sektoral dalam praktik dan materialitas pelaporan ESG. Profil ESG cenderung menunjukkan perilaku spesifik sektor, dengan

perusahaan di industri ekstraktif biasanya mendapat skor lebih rendah pada dimensi lingkungan karena emisi atau intensitas sumber daya yang tinggi, sementara perusahaan di sektor berorientasi jasa mungkin menunjukkan kinerja yang lebih baik pada kriteria sosial atau tata kelola. Lebih lanjut, pengelompokan skor ESG ke dalam pilar-pilar penyusunnya — Lingkungan, Sosial, dan Tata Kelola — mengungkapkan lapisan kompleksitas tambahan. Misalnya, risiko lingkungan seperti intensitas karbon dan dampak keanekaragaman hayati sangat menonjol dalam utilitas, energi, dan manufaktur, sementara isu sosial seperti hak buruh atau keterlibatan masyarakat lebih menonjol dalam barang konsumsi dan ritel. Sebaliknya, kualitas tata kelola sangat penting dalam jasa keuangan dan struktur perusahaan dengan kompleksitas tinggi.

Heterogenitas sektoral relevansi ESG menggarisbawahi keterbatasan penerapan sistem penilaian yang seragam di berbagai industri. Penelitian menunjukkan bahwa kegagalan memperhitungkan materialitas ESG spesifik industri dapat menyebabkan penilaian yang menyesatkan dan strategi investasi yang tidak selaras. Hal ini menyebabkan meningkatnya penekanan pada tolok ukur yang disesuaikan sektor dan penilaian materialitas ganda, yang mengevaluasi tidak hanya bagaimana faktor-faktor ESG memengaruhi perusahaan, tetapi juga bagaimana perusahaan memengaruhi sistem lingkungan dan sosial. Dinamika ini memperkuat kebutuhan akan pendekatan evaluasi ESG yang disesuaikan dan peka konteks, terutama ketika menggunakan analitik berbasis AI.

Sejalan dengan itu, perbedaan dalam peringkat ESG semakin memperumit lanskap. Sebagaimana ditunjukkan oleh studi perbandingan, skor ESG dari berbagai penyedia seringkali berbeda secara substansial karena beragamnya rangkaian indikator, teknik pengukuran, dan skema pembobotan. Kurangnya konvergensi ini sangat kontras dengan peringkat kredit, yang biasanya menunjukkan konsistensi antar-lembaga yang lebih tinggi. Tidak adanya metodologi yang harmonis dan sifat diskresioner dari praktik pengungkapan berkontribusi pada apa yang disebut "kebingungan agregat" dalam evaluasi ESG.

Tantangan struktural lebih lanjut dalam arsitektur data ESG muncul dari adanya bias terkait ukuran. Ketersediaan dan granularitas data ESG terkonsentrasi secara tidak proporsional di antara perusahaan-perusahaan besar yang terdaftar di bursa saham, yang lebih mungkin tunduk pada persyaratan pengungkapan wajib dan memiliki sumber daya kelembagaan untuk terlibat dalam pelaporan keberlanjutan terstruktur. Sebaliknya, UKM seringkali tidak memiliki kapasitas, insentif, atau kewajiban regulasi untuk mengungkapkan informasi terkait ESG, sehingga mengakibatkan kurangnya representasi dalam kumpulan data ESG arus utama. Bias ukuran ini memiliki implikasi yang mendalam: membatasi generalisasi penilaian ESG dan berpotensi menghasilkan tolok ukur yang bias yang mencerminkan praktik sebagian kecil pelaku pasar.

Studi empiris menyoroti bahwa peringkat dan skor ESG berkorelasi secara sistematis dengan ukuran perusahaan, dengan perusahaan yang lebih besar menerima evaluasi ESG yang lebih lengkap dan positif, sebagian karena kemampuan mereka untuk membentuk narasi, memformalkan kebijakan, dan menavigasi kompleksitas kerangka kerja pengungkapan ESG. Bias ini dapat mendistorsi konstruksi portofolio, mengarahkan indeks ESG ke arah kepemilikan

saham berkapitalisasi besar, dan mengaburkan kinerja keberlanjutan perusahaan yang lebih kecil yang mungkin menerapkan praktik yang bermakna di luar jalur formal.

Pendekatan berbasis AI menawarkan alat untuk memperbaiki sebagian ketidakseimbangan ini. Model pembelajaran mesin terawasi dapat dilatih pada kumpulan data berlabel dari perusahaan besar dan diterapkan untuk memperkirakan proksi ESG untuk UKM menggunakan data keuangan terstruktur, karakteristik sektoral, dan pengungkapan yang dapat diakses publik. Teknik NLP dapat menambang situs web, sumber berita lokal, dan laporan komunitas untuk mengekstrak sinyal kualitatif dari perusahaan yang lebih kecil atau swasta, memperluas basis informasi melampaui basis data ESG tradisional. Alat-alat ini juga dapat membantu mengidentifikasi inisiatif keberlanjutan spesifik konteks yang dilakukan oleh UKM, yang tidak tercakup dalam taksonomi standar atau kerangka kerja pelaporan.

Namun demikian, inferensi algoritmik yang diterapkan pada UKM harus didekati dengan hati-hati. Perbedaan skala operasional, kualitas data, dan kapasitas kelembagaan dapat menyebabkan ketidakstabilan model dan berkurangnya generalisasi. Karena alasan ini, penelitian terbaru menganjurkan pengembangan kerangka kerja penilaian ESG yang disesuaikan untuk UKM, alih-alih mengandalkan versi model yang diperkecil yang dirancang untuk perusahaan besar. Kerangka kerja semacam itu akan mengenali kendala kontekstual dan profil materialitas yang unik bagi perusahaan yang lebih kecil, sehingga mendorong lanskap yang lebih adil dan inklusif untuk integrasi ESG.

Teknologi AI menawarkan alat yang berharga untuk mengatasi beberapa tantangan data ini. Model pembelajaran terawasi dapat digunakan untuk memperkirakan proksi ESG untuk perusahaan yang tidak diperingkat dengan pelatihan menggunakan informasi keuangan dan non-keuangan yang tersedia untuk publik. Model-model tersebut memperluas analisis ESG ke UKM dan perusahaan swasta, yang berpotensi memperluas cakupan keuangan berkelanjutan. Lebih lanjut, model AI dapat mengintegrasikan aliran data alternatif, seperti citra satelit, sentimen tekstual dari media, atau laporan LSM, sehingga menyediakan indikator pelengkap yang dapat mengimbangi keterbatasan dalam pengungkapan sukarela.

Teknik tanpa pengawasan seperti pengelompokan dan reduksi dimensionalitas memungkinkan identifikasi pola-pola ESG laten, segmentasi perusahaan ke dalam kelompok-kelompok yang relevan dengan ESG, dan mengungkap dimensi-dimensi keberlanjutan yang tidak tercakup oleh taksonomi standar. Hal ini khususnya relevan untuk mengidentifikasi sinyal-sinyal awal risiko transisi atau kerentanan reputasi yang mungkin terlewatkan oleh metrik tradisional. Dikombinasikan dengan NLP, model-model ini memungkinkan pemantauan dinamis terhadap perkembangan terkait ESG, yang memungkinkan investor untuk menangkap risiko keberlanjutan yang berkembang pesat.

Meningkatnya permintaan akan produk investasi yang selaras dengan ESG telah meningkatkan tekanan pada infrastruktur data yang mendukung penilaian keberlanjutan. Investor institusional membutuhkan sinyal ESG yang terperinci, andal, dan berwawasan ke depan untuk membangun portofolio yang selaras dengan tujuan keuangan dan dampak. Investor ritel, yang semakin terlibat dalam investasi berkelanjutan melalui platform robo-

advisory dan dana tematik, juga menuntut data ESG yang transparan dan komprehensif untuk menginformasikan pilihan mereka.

Permintaan pasar telah mendorong inovasi dalam layanan data ESG, dengan platform berbasis fintech dan AI yang menawarkan solusi analitik yang mengintegrasikan data terstruktur dan tidak terstruktur, menyediakan pemantauan ESG secara real-time, dan memungkinkan metodologi penilaian ESG yang disesuaikan. Namun, munculnya penyedia alternatif ini juga menimbulkan pertanyaan tentang transparansi model, replikasi, dan keselarasan dengan standar regulasi, terutama ketika data ESG dimasukkan ke dalam keputusan investasi dengan implikasi fidusia.

Peluang yang muncul terletak pada pengembangan model penilaian ESG hibrida yang menggabungkan indikator berbasis pengungkapan tradisional dengan sinyal berbasis perilaku secara real-time. Model-model ini dapat menggabungkan data emisi tingkat perusahaan, skor transparansi rantai pasok, atau indeks sentimen untuk menyusun penilaian ESG komposit yang disesuaikan dengan mandat investasi tertentu. Teknik AI, khususnya pembelajaran ansambel, memfasilitasi integrasi lapisan data yang beragam tersebut ke dalam kerangka kerja prediktif yang koheren.

Namun, bahkan dengan peningkatan yang didukung AI, data ESG tetap rentan terhadap ketidakpastian makroekonomi, non-stasioneritas, dan siklus umpan balik yang tertunda antara kinerja keberlanjutan dan hasil keuangan. Oleh karena itu, investor dan regulator harus menafsirkan analitik ESG dengan memahami keterbatasannya, dan mendukung pengembangan standar bersama serta praktik verifikasi data untuk mendorong keterbandingan dan integritas dalam penilaian terkait ESG.

### **3.6. APLIKASI DALAM MANAJEMEN RISIKO DAN PELUANG TERKAIT ESG**

Integrasi faktor-faktor ESG ke dalam kerangka kerja manajemen risiko sedang membentuk kembali praktik keuangan kontemporer. Alih-alih dibingkai sebagai label etika atau reputasi, profil ESG semakin dipahami dalam literatur ilmiah sebagai variabel dengan dampak terukur terhadap volatilitas imbal hasil, probabilitas gagal bayar, dan ketahanan portofolio.

Dalam perdebatan akademis, dua perspektif utama muncul: yang pertama memandang ESG sebagai pengungkit untuk mengurangi risiko idiosinkratik dan sistemik; yang kedua sebagai alat untuk mengidentifikasi peluang strategis. Namun, bukti empiris masih belum konvergen. Beberapa studi menunjukkan bahwa perusahaan dengan profil ESG yang solid menunjukkan kinerja yang lebih stabil selama guncangan sistemik, seperti krisis pandemi 2020, sementara studi lain menekankan bahwa efektivitas ESG sebagai mekanisme perlindungan sangat bergantung pada konteks sektoral, cakrawala waktu, dan kualitas data ESG yang tersedia. Perbedaan ini mencerminkan dua aliran konseptual yang terdapat dalam literatur keuangan: manajemen risiko di satu sisi dan penciptaan nilai strategis serta inovasi berkelanjutan di sisi lain.

Aspek sentral dalam area ini adalah kualitas dan konsistensi pengungkapan ESG. Transparansi dalam mengomunikasikan kinerja lingkungan dan sosial berkontribusi pada mitigasi risiko reputasi, sementara praktik yang tidak transparan atau yang dianggap

instrumental memicu risiko greenwashing dan hilangnya kepercayaan pemangku kepentingan. Teknik NLP tingkat lanjut yang diterapkan pada siaran pers, laporan keuangan, media sosial, dan sumber jurnalistik memungkinkan deteksi dini sinyal peringatan, memfasilitasi pemantauan dinamis dimensi ESG yang berisiko.

Manajemen risiko reputasi melalui perangkat AI dapat diperkuat lebih lanjut dengan penggunaan gabungan NLP dan model prediktif, yang tidak hanya mengidentifikasi peristiwa kontroversial tetapi juga memperkirakan kemungkinan evolusi dan dampaknya terhadap nilai perusahaan. Misalnya, model yang dilatih pada kumpulan data historis krisis reputasi dapat digunakan untuk mengenali konfigurasi naratif yang serupa, memicu peringatan otomatis bagi petugas risiko dan manajer portofolio.

Dari perspektif metodologis, kecerdasan buatan memungkinkan pemodelan hubungan ESG-risiko yang lebih fleksibel dan adaptif. Model terawasi seperti random forest, XGBoost, dan gradient boosting, jika dikombinasikan dengan indikator akuntansi dan sinyal ESG, mampu mengestimasi ukuran risiko sistemik bersyarat seperti beta dinamis, sehingga meningkatkan sensitivitas model risiko terhadap faktor-faktor non-linier atau yang hampir tidak dapat diamati. Lebih lanjut, integrasi sinyal tekstual melalui NLP memungkinkan pembaruan dinamis estimasi risiko, yang mencerminkan perkembangan regulasi, kontroversi, atau perubahan perilaku perusahaan secara real-time.

Di sektor-sektor dengan regulasi tinggi dan inovasi intensif seperti teknologi, telekomunikasi, dan layanan kesehatan, pilar Sosial dan Tata Kelola tampaknya memiliki dampak yang lebih nyata terhadap pengurangan volatilitas dibandingkan dengan komponen Lingkungan, yang justru lebih relevan di sektor-sektor dengan emisi tinggi. Heterogenitas ini memperkuat perlunya pendekatan spesifik sektor terhadap manajemen risiko ESG.

AI juga dapat berkontribusi secara substansial dalam menghilangkan bias ukuran yang umum terjadi dalam penilaian ESG. Saat ini, ketersediaan data ESG sangat condong ke arah perusahaan tercatat dan besar, sementara UKM sebagian besar masih dikecualikan dari sistem pemeringkatan tradisional. Namun, model AI yang diawasi dapat dilatih pada kumpulan data ESG dari perusahaan tercatat untuk memperkirakan proksi ESG bagi perusahaan yang tidak diperingkat, dengan mengintegrasikan informasi akuntansi, sektoral, dan tekstual dari sumber publik. Pendekatan ini dapat menawarkan solusi yang skalabel, replikasi, dan lebih inklusif yang mampu memperluas cakupan manajemen risiko ESG bahkan hingga entitas yang secara tradisional terpinggirkan.

Lebih lanjut, model-model tersebut memungkinkan pembentukan proksi yang terharmonisasi yang mengatasi perbedaan antar penyedia pemeringkatan ESG, meningkatkan konsistensi metodologi evaluasi dan komparabilitas profil risiko. Penggunaan AI dalam konteks yang kurang teregulasi dapat memungkinkan estimasi metrik ESG untuk UKM dan juga mendukung mereka dalam membangun praktik pelaporan terstruktur. Adopsi model AI untuk pembuatan laporan ESG secara otomatis dari dokumen internal, komunikasi pemangku kepentingan, dan laporan sosial merupakan terobosan yang menjanjikan untuk mendemokratisasi transparansi keberlanjutan.

Selain pengurangan risiko, analisis ESG memungkinkan identifikasi lintasan pertumbuhan strategis. Perusahaan dengan strategi ESG proaktif lebih mudah mengakses instrumen keuangan seperti obligasi hijau dan pinjaman terkait keberlanjutan, sehingga mendapatkan keuntungan dari kondisi yang lebih menguntungkan dalam hal biaya modal dan reputasi pasar. Lebih lanjut, perusahaan-perusahaan ini seringkali lebih responsif dalam mendeteksi sinyal regulasi atau transformasi perilaku investor, memosisikan diri sebagai pelopor di sektor-sektor yang terkait dengan transisi berkelanjutan, energi bersih, atau inklusi sosial.

Pada tingkat makroekonomi, ESG juga memperoleh relevansi dalam konteks stabilitas keuangan. Studi terbaru menunjukkan bahwa perekonomian yang dicirikan oleh penetrasi ESG yang tinggi, yang diukur melalui investasi yang bertanggung jawab, regulasi yang lebih maju, dan akuntabilitas kelembagaan, cenderung menunjukkan kerentanan yang lebih rendah terhadap guncangan sistemik dan ketahanan yang lebih besar dalam kepercayaan dan sirkuit keuangan. Dalam hal ini, AI dapat berkontribusi pada definisi perangkat makroprudensial yang canggih dengan mengintegrasikan indikator ESG ke dalam kerangka kerja peringatan dini, uji ketahanan, dan agregasi risiko.

Secara khusus, model AI dapat digunakan untuk memantau konsentrasi eksposur ESG dalam portofolio sistemik dan untuk mensimulasikan dampak iklim ekstrem atau peristiwa sosial terhadap stabilitas sistem keuangan.

Contoh aplikasi yang menjanjikan adalah penggunaan AI untuk simulasi skenario spesifik ESG. Simulasi ini memungkinkan penilaian ketahanan perusahaan dan portofolio dalam skenario transisi iklim, perubahan regulasi, atau guncangan reputasi. Melalui teknik pembelajaran penguatan dan optimasi Bayesian, dimungkinkan untuk membangun skenario yang dikondisikan pada lintasan ESG alternatif, yang menghasilkan alat uji stres yang lebih terperinci dan bermakna.

Terakhir, model AI yang diterapkan pada analisis ESG dapat digunakan untuk mendeteksi sinyal awal inovasi berkelanjutan. Analisis kluster dan teknik reduksi dimensionalitas (misalnya, t-SNE, PCA) memungkinkan identifikasi perusahaan pionir yang mengadopsi praktik transparansi rantai pasokan, teknologi rendah emisi, atau model tata kelola inklusif. Alat-alat ini dapat memperkaya profil informasi investor, memungkinkan strategi alfa berkelanjutan berdasarkan sinyal-sinyal non-konvensional. Konsep alpha berkelanjutan, yang diperkenalkan oleh Kotsantonis dan Serafeim (2019), mengacu pada imbal hasil berlebih yang dapat dicapai melalui integrasi informasi faktor-faktor ESG yang canggih, terutama dalam konteks di mana faktor-faktor ini belum sepenuhnya tercermin dalam harga pasar.

Agar perangkat ini efektif, model AI harus dirancang agar hemat, mudah diakses, dan peka terhadap konteks, serta menghindari solusi yang tidak transparan atau terlalu rumit. Integrasi faktor-faktor ESG yang efektif ke dalam sistem manajemen risiko membutuhkan kompetensi interdisipliner, struktur tata kelola yang mampu menerjemahkan informasi ESG menjadi tindakan, dan proses pengambilan keputusan yang didasarkan pada bukti dan transparansi.

## BAB 4

### MENGELOLA KOMPLEKSITAS, RISIKO, DAN PERTIMBANGAN ETIKA

#### 4.1. MENAVIGASI KOMPLEKSITAS, KETIDAKPASTIAN, DAN DESAIN ETIS

Integrasi AI ke dalam sistem keuangan telah menghasilkan dinamika baru kompleksitas, umpan balik, dan saling ketergantungan, yang berimplikasi pada fungsi pasar dan stabilitas kelembagaan. Seiring model AI berinteraksi dengan lingkungan data yang heterogen dan beradaptasi dengan kondisi strategis yang terus berkembang, model tersebut membentuk kembali mekanisme utama transmisi risiko, pembentukan volatilitas, dan pengambilan keputusan di seluruh domain keuangan.

Bab ini mengeksplorasi bagaimana AI dapat memitigasi atau memperkuat risiko keuangan dan sistemik, tergantung pada bagaimana model dirancang, diatur, dan diterapkan. Bab ini mengkaji fitur struktural kompleksitas yang dimungkinkan oleh AI, peran agen algoritmik dalam perilaku pasar adaptif, dan kondisi yang dapat memicu konvergensi atau ketidakstabilan model. Perhatian juga diberikan pada dimensi etika dan sosial dari keuangan algoritmik, serta pendekatan pengawasan yang dikembangkan untuk mengatasi risiko yang terkait dengan otomatisasi skala besar di domain sensitif.

#### 4.2. KOMPLEKSITAS DALAM SISTEM KEUANGAN BERBASIS AI

Integrasi AI dan ML ke dalam sistem keuangan memperkenalkan lapisan transformatif berupa kompleksitas struktural, operasional, dan perilaku. Sistem keuangan tradisional terutama dibentuk oleh model yang dibangun berdasarkan asumsi linear, persamaan bentuk tertutup, dan hubungan berbasis parameter yang berasal dari teori ekonomi.

Model-model ini, meskipun mudah dianalisis, seringkali kurang fleksibel untuk mengakomodasi sifat pasar keuangan modern yang dinamis dan berdimensi tinggi. Sebaliknya, sistem AI, terutama yang menggunakan algoritma non-parametrik dan arsitektur pembelajaran mendalam, beroperasi dalam ruang epistemologis yang secara fundamental berbeda, di mana pembelajaran dari data, alih-alih menentukan bentuk fungsional, merupakan pendekatan yang dominan.

Sistem keuangan berbasis AI pada dasarnya adaptif, berbasis data, dan peka konteks. Sistem ini memproses sumber data heterogen, termasuk indikator keuangan terstruktur, informasi tekstual tidak terstruktur, dan sinyal perilaku, seringkali secara waktu nyata (real-time). Pergeseran ini mendukung peningkatan kemampuan prediktif tetapi juga meningkatkan opasitas, ketergantungan jalur, dan endogenitas proses keuangan. Algoritma yang dilatih dalam lingkungan yang terus berkembang dapat mengkalibrasi ulang strateginya secara dinamis, sehingga menimbulkan putaran umpan balik, interaksi yang tidak diinginkan, dan perilaku yang muncul yang menantang gagasan tradisional tentang keseimbangan dan stabilitas.

Ciri penting kompleksitas dalam sistem AI adalah adanya dinamika pembelajaran multi-agen. Ketika beberapa agen otonom, seperti model pembelajaran penguatan yang digunakan

dalam perdagangan, penyediaan likuiditas, atau penyeimbangan kembali portofolio, berinteraksi dalam lingkungan pasar bersama, mereka menghasilkan saling ketergantungan yang sulit diantisipasi atau dikendalikan. Agen-agen ini dapat berkonvergensi menuju perilaku suboptimal secara kolektif, terutama ketika dilatih dengan fungsi imbalan atau data pasar yang serupa. Sebagaimana ditunjukkan dalam simulasi empiris, kegagalan koordinasi dan efek crowding dapat menyebabkan dislokasi pasar, flash crash, atau pergeseran rezim yang bersifat endogen terhadap arsitektur keuangan yang diperkuat AI.

Lingkungan multi-agen ini juga mewujudkan rasionalitas terbatas, di mana agen beroperasi berdasarkan informasi lokal yang terbatas, alih-alih optimasi global. Dalam situasi yang bersifat adversarial seperti perdagangan frekuensi tinggi, perilaku strategis antar agen pembelajaran dapat mengakibatkan overfitting kompetitif, pergeseran adversarial, dan destabilisasi dinamika pasar. Sifat adaptif dari interaksi ini menyiratkan bahwa risiko sistemik dapat berasal tidak hanya dari guncangan eksogen tetapi juga dari amplifikasi endogen dari proses adaptasi lokal.

Dimensi lain dari kompleksitas yang diinduksi AI berasal dari ireduksibilitas komputasional, sebuah ciri khas sistem yang keadaan masa depannya tidak dapat diprediksi kecuali melalui simulasi aktual. Dalam sistem seperti itu, dinamika jangka panjang sulit disimpulkan secara analitis, sehingga secara inheren tidak transparan terhadap pemodelan risiko dan intervensi kebijakan. Akibatnya, perangkat konvensional pengawasan keuangan, yang berakar pada linearitas, stasioneritas, dan analisis ekuilibrium, kesulitan untuk mengatasi perilaku sistem yang digerakkan oleh AI yang bergantung pada jalur.

Kompleksitas yang diinduksi AI semakin diperparah oleh komposisi model dan arsitektur ansambel. Lembaga keuangan semakin banyak menerapkan sistem AI yang saling terhubung dan terdiri dari berbagai lapisan, mulai dari modul prapemrosesan hingga ekstraktor sinyal, mesin prediktif, dan lapisan pendukung keputusan. Tumpukan modular ini, yang seringkali mengintegrasikan komponen berbasis statistik dan pembelajaran mesin (ML), menghadirkan tantangan baru dalam hal kalibrasi, ketertelusuran, dan propagasi kesalahan. Penggunaan kembali model yang telah dilatih sebelumnya, kumpulan data bersama, dan API pihak ketiga di seluruh lembaga juga menyebabkan saling ketergantungan infrastruktur dan kerentanan bersama, yang memperkuat risiko sistemik.

Evolusi menuju infrastruktur yang berpusat pada AI ini memerlukan rekonseptualisasi kerangka kerja tata kelola. Model tata kelola hibrida telah muncul sebagai respons yang menjanjikan, menggabungkan fleksibilitas algoritmik dengan akuntabilitas prosedural dan pengawasan yang melibatkan manusia. Kerangka kerja ini melibatkan mekanisme validasi berlapis, termasuk pengujian berbasis skenario, uji stres adversarial, dan pemantauan penyimpangan model secara real-time. Pagar pembatas seperti batas kecepatan perdagangan, batasan paparan algoritmik, dan batasan frekuensi pelatihan ulang direkomendasikan untuk menahan amplifikasi umpan balik dan memastikan ketahanan operasional.

Dari perspektif teori jaringan, sistem keuangan yang diperkuat oleh AI menampilkan topologi yang kompleks, di mana adaptasi tingkat agen dapat menyebabkan efek konsentrasi dan titik kritis. Perangkat dari ilmu kompleksitas, seperti pemetaan penularan, sentralitas

vektor eigen, dan metrik propagasi pengaruh, semakin banyak diterapkan untuk mendeteksi simpul kritis dan tautan rapuh dalam ekosistem algoritmik. Metrik ini membantu mengidentifikasi aktor atau komponen yang kegagalannya dapat memicu kaskade sistemik, yang mendukung perancangan intervensi pengawasan yang terarah.

Infrastruktur pemantauan model harus berevolusi agar sesuai dengan kecepatan dan opasitas sistem AI. Diagnostik waktu nyata (real-time), seperti deteksi pergeseran distribusi, identifikasi anomali, dan analisis ketahanan adversarial, sangat penting untuk melacak perilaku model dalam kondisi pasar langsung. Metrik yang membandingkan keluaran model lintas agen, interval temporal, atau kumpulan data referensi dapat menyoroti fenomena konvergensi, herding, atau divergensi. Dalam konteks ini, dasbor pengawasan yang didukung oleh AI sendiri sedang dikembangkan untuk memantau ekosistem keuangan dalam skala besar. Alat pengawasan ini, yang didefinisikan sebagai SupTech, akan dibahas di bagian terakhir bab ini.

Diskusi kebijakan terkini menekankan perlunya kerangka kerja akuntabilitas algoritmik yang menggabungkan standar teknis dengan transparansi kelembagaan. Ini mencakup dokumentasi wajib arsitektur model, silsilah data pelatihan, pengaturan hiperparameter, dan audit kinerja dalam berbagai kondisi pasar. Penyelarasan lintas sektor dengan regulasi perlindungan data, mandat stabilitas keuangan, dan prinsip-prinsip etika AI diperlukan untuk memastikan pengawasan yang koheren dan dapat ditegakkan.

Yang penting, kompleksitas sistem keuangan berbasis AI bukanlah anomali sementara, melainkan karakteristik struktural keuangan algoritmik. Mengelola kompleksitas ini tidak hanya membutuhkan kecanggihan teknologi, tetapi juga kemampuan adaptasi kelembagaan dan tata kelola interdisipliner. Keterlibatan kolaboratif antara regulator keuangan, ilmuwan data, ekonom perilaku, dan insinyur sistem sangat penting untuk merancang kerangka kerja pengawasan yang dinamis, peka konteks, dan tangguh terhadap guncangan inovasi.

Seiring pasar keuangan semakin dimediasi secara algoritmik, pemahaman dan pengelolaan kompleksitas sistemik menjadi landasan keuangan digital yang berkelanjutan. Tujuannya bukanlah untuk menghilangkan kompleksitas, yang tidak layak maupun diinginkan, tetapi untuk membuatnya dapat dipahami, dapat diatur, dan kompatibel dengan tujuan yang lebih luas yaitu stabilitas keuangan, keadilan, dan inovasi.

#### **4.3. KECERDASAN BUATAN UNTUK VOLATILITAS, ADAPTASI, DAN STABILITAS PASAR**

Penerapan AI di pasar keuangan memiliki implikasi mendalam bagi dinamika volatilitas, perilaku adaptif, dan arsitektur stabilitas pasar. Volatilitas, ukuran fluktuasi harga aset, secara tradisional dimodelkan sebagai proses stokastik yang didorong oleh variabel makroekonomi, kondisi likuiditas, dan sentimen investor. Dengan semakin banyaknya pengaruh sistem berbasis AI terhadap operasi pasar, sumber volatilitas baru telah muncul yang bersifat endogen terhadap interaksi algoritmik dan perilaku model. Efek ini menantang model volatilitas tradisional dan membutuhkan kerangka kerja yang diperbarui yang mampu menggabungkan dinamika adaptif, frekuensi tinggi, dan sensitif terhadap umpan balik.

Sistem perdagangan berbasis AI, terutama yang berbasis pembelajaran penguatan dan jaringan saraf dalam, mengoptimalkan kinerja melalui pembelajaran coba-coba dalam

lingkungan pasar yang terus berkembang. Agen-agen ini secara dinamis menyesuaikan diri dengan informasi baru, strategi pesaing, dan kondisi lingkungan. Namun, ketika beberapa agen berinteraksi secara real-time menggunakan algoritma yang serupa, mereka dapat menghasilkan putaran umpan balik yang memperkuat volatilitas jangka pendek. Perilaku semacam itu telah diamati dalam kasus flash crash dan gangguan likuiditas, di mana konvergensi strategi algoritmik memicu penarikan pesanan berjenjang dan dislokasi harga.

Di luar peristiwa volatilitas episodik, sistem AI memengaruhi sifat statistik imbal hasil aset dari waktu ke waktu. Model ML sering kali dikalibrasi ulang berdasarkan data waktu nyata, sehingga menimbulkan ketidakstasioneran dalam distribusi imbal hasil. Ini berarti asumsi dasar tentang stabilitas dan distribusi imbal hasil mungkin tidak lagi berlaku, terutama selama transisi pasar. Kehadiran rezim data yang bergeser menantang efektivitas model estimasi risiko klasik seperti GARCH dan Value at Risk (VaR), yang mengasumsikan pola historis yang relatif stabil. Meskipun perilaku adaptif ini dapat meningkatkan akurasi peramalan selama periode tenang, hal ini juga dapat memperburuk ketidakstabilan model dalam skenario stres, yang menyebabkan estimasi risiko ekor yang terlalu rendah.

Lebih lanjut, pengelompokan volatilitas, di mana peristiwa volatilitas tinggi cenderung mengikuti satu sama lain, merupakan fakta khas pasar keuangan yang mungkin secara tidak sengaja diperkuat oleh sistem AI. Dalam lingkungan dengan komunikasi antar-algoritmik yang tinggi dan pengawasan manusia yang minimal, strategi adaptif dapat memperkuat pergerakan pasar, alih-alih meredamnya. Misalnya, algoritma dapat secara bersamaan menyesuaikan posisi sebagai respons terhadap guncangan yang dirasakan, yang mengarah pada siklus beli atau jual yang saling memperkuat. Pola ini, yang dikenal sebagai perdagangan umpan balik positif, meningkatkan autokorelasi dalam volatilitas dan dapat menciptakan ketidakstabilan pasar lokal.

AI juga mengubah struktur adaptif para pelaku pasar. Investor ritel semakin mengandalkan saran algoritmik melalui robo-advisor, sementara pedagang institusional menggunakan algoritma eksekusi untuk mengoptimalkan penempatan pesanan. Manajer portofolio menggunakan sinyal berbasis AI untuk alokasi aset dan penyeimbangan ulang risiko. Ketika agen manusia dan mesin merespons perilaku satu sama lain, jaringan adaptasi yang kompleks pun muncul. Interaksi ini menciptakan sistem umpan balik berlapis-lapis di mana keluaran dari satu model memengaruhi masukan model lainnya, menghasilkan pola volatilitas endogen. Yang penting, dinamika ini tidak serta merta menyiratkan ketidakstabilan.

Sebaliknya, model AI dapat meningkatkan ketahanan pasar dengan memberikan peringatan dini dan respons yang lebih cepat terhadap sinyal risiko. Algoritma deteksi anomali, yang dilatih untuk memantau indikator mikrostruktural seperti spread bid-ask, revisi kuota, dan penundaan eksekusi, dapat mendeteksi tanda-tanda awal tekanan pasar dan memicu mekanisme penyediaan likuiditas atau pengendalian risiko. Lebih lanjut, teknik NLP yang diterapkan pada berita keuangan, pengumuman regulasi, dan media sosial dapat mengekstrak sentimen dan mendeteksi risiko yang muncul, menawarkan pelengkap berwawasan ke depan untuk data tradisional.

Dalam skala sistemik, bank sentral dan regulator menerapkan model AI untuk memantau dan memprediksi ketidakstabilan keuangan. Aplikasi ini menggabungkan kumpulan data heterogen, seperti arus pembayaran, eksposur derivatif, dan jaringan pinjaman antarbank, untuk mengembangkan sistem peringatan dini makroprudensial. Pengklasifikasi pembelajaran mesin dan algoritma pengelompokan digunakan untuk mengidentifikasi kelompok risiko laten, melacak saluran penularan, dan mensimulasikan skenario propagasi tekanan. Dalam bidang ini, aplikasi AI di sektor keuangan semakin banyak digunakan untuk mendukung pengujian stres yang selaras dengan ESG, segmentasi risiko, dan pemantauan ketahanan, yang menunjukkan bagaimana pengelompokan berdasarkan ESG dan data pasar dapat mengungkap lembaga yang rentan secara struktural dalam ekosistem keuangan.

Namun demikian, adopsi AI yang meluas dapat mengarah pada konvergensi model. Lembaga yang menggunakan algoritma serupa, dilatih pada kumpulan data yang tumpang tindih dan dioptimalkan untuk tujuan yang sebanding, dapat merespons sinyal pasar secara identik. Herding algoritmik ini membatasi diversifikasi strategi dan memperbesar paparan sistemik terhadap guncangan umum. Hasilnya adalah penurunan kapasitas adaptif di tingkat sistem, di mana respons yang homogen mengurangi ketahanan dan meningkatkan kemungkinan kegagalan terkoordinasi.

Untuk memitigasi risiko ini, infrastruktur pasar harus menanamkan batasan pada perilaku AI. Contohnya termasuk pemutus sirkuit yang menghentikan sementara perdagangan selama volatilitas abnormal, waktu istirahat minimum untuk pesanan guna mencegah pengisian kuota, dan aturan margin dinamis untuk mengelola leverage. Badan regulator juga bereksperimen dengan registrasi algoritma, jejak audit, dan uji stres wajib untuk model perdagangan. Intervensi ini berupaya untuk menegakkan batasan keamanan di sekitar perilaku algoritmik, mencegah ketidakstabilan tanpa menghambat inovasi.

Batas lain dalam pengendalian volatilitas adalah keragaman model. Mendorong pengembangan model dengan struktur, masukan data, dan tujuan pembelajaran yang berbeda dapat meningkatkan ketahanan sistemik. Pembelajaran ensemble, yang menggabungkan prakiraan dari beberapa model, mengurangi ketergantungan pada satu prediksi tunggal dan membantu memperhalus kesalahan idiosinkratik. Pendekatan ini juga dapat meredam volatilitas dengan menggabungkan beragam reaksi terhadap guncangan informasi.

Pemodelan deret waktu tingkat lanjut semakin meningkatkan prediksi volatilitas. Jaringan memori jangka pendek (LSTM), jaringan konvolusional temporal (TCN), dan model berbasis Transformer semakin banyak digunakan untuk menangkap ketergantungan temporal yang kompleks dalam harga aset. Model-model ini mengungguli model GARCH dan ARIMA tradisional dalam kondisi peralihan rezim dan non-linier. Ketika dikombinasikan dengan indikator makroekonomi, metrik risiko ESG, atau data peristiwa geopolitik, model-model ini memungkinkan sistem prediktif yang lebih responsif terhadap sifat multi-kausal volatilitas.

Akibatnya, integrasi AI di pasar keuangan telah memperkenalkan peran ganda dalam manajemen volatilitas. Di satu sisi, integrasi ini menciptakan sumber baru fluktuasi pasar endogen karena adaptasi yang cepat, putaran umpan balik, dan koordinasi strategis antar algoritma. Di sisi lain, AI menyediakan perangkat canggih untuk deteksi dini, respons dinamis,

dan desain yang tangguh. Keseimbangan antara efek-efek ini bergantung pada perlindungan kelembagaan, keragaman model, dan keselarasan tujuan AI dengan tujuan stabilitas yang lebih luas. Pendekatan sistemik, yang berlandaskan regulasi kehati-hatian, arsitektur teknis yang kuat, dan pemantauan waktu nyata (real-time), sangat penting untuk memanfaatkan potensi stabilisasi AI sekaligus memitigasi umpan balik yang mengganggu stabilitas.

#### **4.4. IMPLIKASI ETIS DAN SOSIAL DARI KECERDASAN BUATAN DALAM KEUANGAN**

Integrasi teknologi AI dan ML ke dalam sistem keuangan menghadirkan lanskap pertimbangan etis dan sosial yang kompleks. Seiring dengan semakin memengaruhi keputusan pemberian pinjaman, praktik perdagangan, pemodelan risiko, dan interaksi klien, isu-isu terkait keadilan, akuntabilitas, dan kesetaraan sosial semakin mengemuka. Isu-isu ini bukan sekadar filosofis; namun memiliki implikasi material terhadap kepatuhan regulasi, risiko reputasi, dan kepercayaan jangka panjang terhadap lembaga keuangan.

Tantangan etis inti terletak pada bias algoritmik. Model AI yang dilatih berdasarkan data keuangan historis dapat secara tidak sengaja mereplikasi dan memperkuat ketimpangan sosial yang ada.

Misalnya, algoritma penilaian kredit yang menggabungkan proksi untuk pendapatan, pendidikan, atau lokasi geografis dapat menghasilkan hasil yang secara tidak proporsional merugikan kelompok minoritas atau terpinggirkan. Ketidakjelasan arsitektur model, terutama dalam pembelajaran mendalam, memperparah masalah dengan menyulitkan identifikasi sumber bias atau justifikasi keputusan individu. Sebagai respons, literatur menyerukan pembelajaran mesin yang memperhatikan keadilan, yang menggabungkan batasan seperti paritas demografis, kesempatan yang sama, atau peluang yang disamakan ke dalam tujuan pelatihan.

Meskipun kekhawatiran ini telah terdokumentasi dengan baik, penelitian yang lebih optimis menyoroti potensi AI untuk meningkatkan inklusi keuangan dan mengurangi disparitas historis. Sistem AI dapat memperluas akses ke produk kredit, asuransi, dan investasi dengan memanfaatkan sumber data alternatif. Misalnya, transaksi uang seluler, pembayaran utilitas digital, dan jejak e-commerce telah digunakan untuk mengembangkan profil kelayakan kredit bagi individu tanpa riwayat perbankan formal. Studi menunjukkan bahwa model berbasis data ini dapat mengungguli metrik tradisional dalam memprediksi pembayaran pinjaman, terutama di pasar negara berkembang. Ketika diimplementasikan dengan perlindungan yang tepat, AI dapat memperluas jangkauan sistem keuangan ke populasi yang kurang terlayani dan mendorong pembangunan ekonomi yang inklusif.

Namun, untuk memastikan inklusi yang etis, penting untuk mengatasi trade-off yang mendasari antara kinerja prediktif dan keadilan. Misalnya, mengoptimalkan model semata-mata untuk akurasi dapat secara tidak sengaja merugikan kelompok dengan akses yang secara historis lebih rendah ke instrumen keuangan formal. Oleh karena itu, teknik debiasing, seperti pembobotan ulang sampel pelatihan, menggabungkan debiasing adversarial, atau menerapkan optimasi yang dibatasi oleh keadilan, harus dilengkapi dengan kerangka kerja

desain partisipatif yang melibatkan komunitas terdampak dalam menentukan metrik dan ambang batas yang relevan.

Isu otonomi dan martabat manusia juga merupakan inti dari perdebatan etika. Sistem AI yang mengotomatiskan nasihat keuangan atau keputusan pinjaman dapat mengurangi kemampuan klien untuk memahami, mempertanyakan, atau menegosiasikan hasil. Hal ini menimbulkan pertanyaan tentang peran pengawasan manusia yang tepat, terutama dalam keputusan berisiko tinggi yang memengaruhi kesejahteraan individu. Kerangka kerja regulasi seperti Undang-Undang AI Uni Eropa menekankan perlunya desain yang melibatkan manusia dalam proses aplikasi berisiko tinggi, yang mengharuskan keputusan akhir tetap ditinjau oleh manusia. Dalam ranah keuangan, hal ini diwujudkan dalam protokol yang dapat dijelaskan, mekanisme banding, dan saluran penyelesaian yang jelas.

Selain hak individu, dampak sosial harus dipertimbangkan. Penerapan sistem algoritmik yang tidak transparan dalam infrastruktur keuangan yang krusial dapat memperkokoh asimetri informasi dan kekuasaan. Lembaga besar yang dilengkapi dengan model AI yang bersifat kepemilikan dapat memperoleh keunggulan kompetitif yang signifikan, yang berpotensi meminggirkan pelaku yang lebih kecil dan mengurangi keragaman pasar. Lebih lanjut, jika dibiarkan, pengambilan keputusan algoritmik dapat memperburuk disparitas geografis dan demografis, mengarahkan aliran modal secara tidak proporsional kepada populasi kaya atau aktif secara digital, sementara mengecualikan yang lain.

Pada tingkat makro, AI yang etis dalam keuangan beririsan dengan tujuan yang lebih luas yaitu kohesi sosial dan stabilitas ekonomi. Penerapan AI yang inklusif mendukung ketahanan keuangan dengan memperluas akses ke jaring pengaman sosial selama guncangan ekonomi, seperti pencairan otomatis kredit mikro atau dana darurat. Sebaliknya, sistem yang dirancang dengan buruk berisiko memperkuat siklus deprivasi, terutama jika klasifikasi algoritmik menjadi kaku seiring waktu dan sulit untuk dibantah atau dibalikkan.

Literatur akademis dan kebijakan menggarisbawahi pentingnya menanamkan etika ke dalam siklus hidup sistem AI. Ini mencakup fase desain (melalui penilaian dampak dan pelibatan pemangku kepentingan), fase pelatihan (melalui debiasing dan ketahanan adversarial), dan fase penerapan (mengggunakan mekanisme pemantauan dan umpan balik). Kolaborasi interdisipliner antara ilmuwan data, ahli etika, akademisi hukum, dan profesional keuangan sangat penting untuk menavigasi tantangan ini. Lebih lanjut, terdapat kebutuhan yang semakin meningkat akan kerangka kerja sertifikasi etika di seluruh industri dan praktik audit algoritmik untuk memverifikasi kepatuhan dan mendorong transparansi.

Konsep penilaian dampak algoritmik (AIA) semakin mendapat perhatian sebagai sarana untuk mengantisipasi dan memitigasi potensi kerugian. Penilaian ini, yang dimodelkan berdasarkan pernyataan dampak lingkungan atau privasi, mendorong lembaga untuk mengkaji siapa yang mungkin terdampak oleh sistem AI tertentu, bagaimana risiko dapat terwujud, dan strategi mitigasi apa yang tepat. Dalam layanan keuangan, AI dapat menjadi landasan inovasi yang bertanggung jawab, terutama dalam domain berdampak tinggi seperti penjaminan kredit, deteksi penipuan, dan perdagangan algoritmik.

Simpulannya, implikasi etis dan sosial AI dalam keuangan bersifat kompleks dan terus berkembang. Mengatasinya membutuhkan solusi teknis dan komitmen normatif terhadap keadilan, inklusi, transparansi, dan akuntabilitas. Sektor keuangan harus merangkul AI yang etis bukan sebagai beban kepatuhan, melainkan sebagai keharusan strategis untuk inovasi yang berkelanjutan dan berkeadilan.

#### **4.5. RISIKO SISTEMIK, TREN REGULASI, DAN ARAH MASA DEPAN**

Transformasi ekosistem keuangan melalui teknologi AI dan ML memunculkan bentuk-bentuk baru risiko sistemik, yang menantang kecukupan kerangka regulasi yang ada, dan mendorong pengembangan strategi pengawasan yang berorientasi masa depan. Seiring sistem AI semakin tertanam dalam infrastruktur perdagangan, mekanisme alokasi kredit, model manajemen risiko, dan perangkat penetapan harga aset, sistem-sistem tersebut memperkenalkan kerentanan yang saling terhubung yang dapat menyebar ke seluruh lembaga dan pasar.

Salah satu sumber signifikan kerapuhan sistemik muncul dari adopsi luas arsitektur model AI dan set data pelatihan yang serupa. Lembaga keuangan sering kali menggunakan algoritma pembelajaran mesin yang sebanding, seperti penguatan gradien, jaringan saraf tiruan dalam, atau pendekatan ansambel, dan menggunakan set data terstandarisasi, yang menghasilkan homogenitas model. Dalam kondisi stres, keseragaman ini dapat menyebabkan perilaku tersinkronisasi seperti herding, perdagangan prosiklikal, atau likuidasi berjenjang. Misalnya, aksi jual algoritmik simultan yang dipicu oleh metrik risiko konvergen dapat memperkuat penurunan pasar, menghasilkan putaran umpan balik nonlinier, dan mengganggu pembentukan harga.

Sentralisasi pemrosesan data dan operasi AI dalam ekosistem berbasis cloud memperparah risiko ini. Ketergantungan pada infrastruktur komputasi bersama dan model berbasis API meningkatkan interdependensi antar pelaku pasar. Ketergantungan semacam itu, meskipun efisien, membuat sistem keuangan lebih sensitif terhadap titik-titik kegagalan umum, termasuk pelanggaran keamanan siber, pemadaman cloud, atau kesalahan sistemik dalam model hulu. Pemetaan interkoneksi digital ini menggunakan metodologi berbasis jaringan semakin direkomendasikan untuk mengidentifikasi simpul-simpul kritis, mengevaluasi risiko penularan, dan merancang perlindungan yang terarah.

Tantangan lain yang muncul menyangkut dinamika temporal dan ketergantungan jalur sistem AI. Tidak seperti model risiko tradisional yang dikalibrasi berdasarkan asumsi statis, algoritma ML terus berkembang seiring dengan penyerapan data baru. Karakteristik ini, meskipun meningkatkan responsivitas, mempersulit ketertelusuran dan akuntabilitas, terutama dalam pengaturan pembelajaran tanpa pengawasan atau pembelajaran penguatan. Oleh karena itu, literatur menyerukan pengenalan perangkat pengawasan regulasi dinamis yang mampu memantau perilaku algoritmik dari waktu ke waktu. Perangkat tersebut dapat mencakup diagnostik model, jejak audit, dan algoritma pengawasan yang tertanam dalam kotak pasir regulasi.

Menanggapi perkembangan ini, regulator keuangan di beberapa yurisdiksi memperbarui perangkat kebijakan mereka. Strategi Keuangan Digital dan Undang-Undang AI Uni Eropa, misalnya, mengamankan klasifikasi risiko, transparansi algoritmik, dan persyaratan pengawasan manusia untuk aplikasi AI di bidang keuangan. Bersamaan dengan itu, Dewan Stabilitas Keuangan (FSB) dan Komite Basel sedang mengeksplorasi risiko stabilitas keuangan terkait AI, menekankan perlunya koordinasi internasional, standar data umum, dan uji stres berbasis skenario.

Di tingkat makroprudensial, AI menghadirkan tantangan sekaligus peluang. Metodologi uji stres dapat dikonfigurasi ulang untuk mensimulasikan interaksi multi-agen di antara algoritma pembelajaran di bawah berbagai guncangan makroekonomi. Demikian pula, sistem peringatan dini dapat mengintegrasikan indikator turunan AI, seperti pergeseran keyakinan model, volatilitas kepentingan fitur, atau divergensi di seluruh prakiraan algoritmik, sebagai proksi untuk kerentanan yang muncul.

AI juga menawarkan cara baru untuk meningkatkan ketahanan sistemik. Perangkat ML yang tervalidasi dan diatur dengan tepat dapat mendeteksi sinyal-sinyal ketidakstabilan yang halus di pasar keuangan, sistem kredit, atau infrastruktur pembayaran lebih awal daripada model tradisional. Misalnya, sistem pengawasan berbasis AI dapat mengidentifikasi pola perdagangan abnormal, tekanan likuiditas, atau penumpukan leverage melalui analisis waktu nyata (real-time) terhadap data frekuensi tinggi, media sosial, dan sumber informasi alternatif.

Namun, kapasitas ganda ini, yang secara bersamaan memitigasi dan memperkuat risiko, menuntut respons kebijakan yang seimbang. Ancaman yang bersifat adversarial, seperti keracunan data atau manipulasi model, menyoroti perlunya ketahanan algoritmik dan integrasi keamanan siber. Lebih lanjut, proliferasi agen otonom menimbulkan pertanyaan terkait tanggung jawab, terutama dalam episode volatilitas yang dipicu oleh algoritma atau arbitrase regulasi.

Para akademisi semakin menganjurkan pendekatan interdisipliner untuk menilai dan mengelola dimensi sistemik ini. Riset kolaboratif lintas bidang keuangan, AI, dan hukum sangat penting untuk mengembangkan arsitektur regulasi yang tangguh dan kompatibel dengan perkembangan ke depan. Ini mencakup perancangan taksonomi risiko yang disesuaikan dengan aplikasi AI, pembedaan antara kerentanan terkait data, kerentanan terkait model, dan kerentanan terkait infrastruktur, serta penyertaan protokol tata kelola yang sesuai.

Prioritas kebijakan yang muncul melibatkan penciptaan kerangka kerja regulasi modular yang dapat mengakomodasi sifat AI yang terus berkembang. Kerangka kerja tersebut dapat menggabungkan ambang batas kepatuhan adaptif, kemampuan audit waktu nyata, dan mandat pengungkapan fleksibel yang mencerminkan heterogenitas dan dinamisme sistem AI. Selain itu, mekanisme regulasi partisipatif, seperti penciptaan standar bersama dengan para pemangku kepentingan industri, dapat memfasilitasi inovasi sekaligus memastikan pengawasan tetap efektif.

Dalam konteks ini, dua tren teknologi yang berbeda namun saling melengkapi telah mendapatkan momentum: Teknologi Regulasi (RegTech) dan Teknologi Pengawasan (SupTech). RegTech berfokus pada bagaimana lembaga keuangan menggunakan teknologi

untuk memenuhi persyaratan kepatuhan secara lebih efektif, misalnya melalui pelaporan otomatis, pemantauan risiko waktu nyata (*real-time*), atau deteksi penipuan. Sementara itu, SupTech mengacu pada transformasi digital lembaga regulator itu sendiri. Inisiatif SupTech bertujuan untuk meningkatkan efisiensi, akurasi, dan pandangan ke depan pengawasan dengan mengintegrasikan AI, pembelajaran mesin, dan analitik big data ke dalam fungsi pengawasan.

Perangkat SupTech mencakup deteksi anomali otomatis dalam transaksi keuangan, analisis pengungkapan dan pengajuan regulasi berbasis NLP, serta pembuatan profil algoritmik lembaga untuk memprioritaskan tindakan pengawasan. Misalnya, beberapa bank sentral dan regulator pasar sedang menguji coba dasbor berbasis AI yang mengintegrasikan aliran data waktu nyata (*real-time*) untuk menandai pola yang tidak teratur dalam perilaku pasar atau eksposur keuangan. Tidak seperti proses pengawasan tradisional yang seringkali bersifat retrospektif dan berbasis sampel, SupTech memungkinkan pemantauan berkelanjutan dan regulasi adaptif, yang sangat berharga dalam lingkungan yang berkembang pesat yang dibentuk oleh keuangan berbasis AI.

Lebih lanjut, penerapan SupTech memfasilitasi evaluasi pengawasan terhadap model algoritmik itu sendiri. Beberapa regulator sedang bereksperimen dengan "asisten peninjau model", yaitu sistem AI yang mampu menganalisis model yang diajukan untuk memastikan kepatuhan terhadap kriteria transparansi, keadilan, dan ketahanan. Hal ini mengaburkan batasan antara fungsi pengawasan dan validasi teknis, sehingga regulator perlu membangun keahlian teknis dan infrastruktur komputasi internal. Evolusi ini mengubah peran pengawasan dari penegak reaktif menjadi pemantau ekosistem yang proaktif dan meleak data.

SupTech juga berinteraksi dengan RegTech dalam memungkinkan arus informasi yang lebih lancar dan terstruktur antara perusahaan dan pengawas. Misalnya, API dan taksonomi data terstandarisasi mendukung pelaporan mesin-ke-mesin, mengurangi beban kepatuhan dan meningkatkan ketepatan waktu. Tujuan utamanya adalah membangun interoperabilitas regulasi, di mana aturan, pengungkapan, dan prosedur pengawasan dikodifikasi dan dieksekusi secara digital oleh algoritma sektor swasta maupun sektor publik, membentuk apa yang oleh beberapa akademisi disebut sebagai "regulasi tertanam".

Perkembangan ini menunjukkan bahwa AI tidak hanya mentransformasi risiko keuangan tetapi juga mekanisme yang dengannya kepatuhan dan pengawasan regulasi dikonseptualisasikan dan dioperasionalkan. SupTech, khususnya, menawarkan kepada regulator sarana untuk mendapatkan kembali visibilitas dan kendali strategis dalam lingkungan yang semakin didominasi oleh agen algoritmik dan lanskap data yang terfragmentasi. Namun, keberhasilan inisiatif SupTech bergantung pada pilihan desain yang cermat, termasuk tata kelola data, kolaborasi antar-lembaga, dan perlindungan yang memadai terhadap bias algoritmik dalam keputusan pengawasan.

Implikasi sistemik AI melampaui implementasi teknis dan koordinasi regulasi. Implikasi tersebut memengaruhi arsitektur aliran modal, konsentrasi kekuatan teknologi, dan efek distribusional dari pengambilan keputusan berbasis algoritma. Memastikan kontribusi AI terhadap sistem keuangan yang berkelanjutan, inklusif, dan stabil membutuhkan komitmen

terhadap transparansi, akuntabilitas, dan desain kebijakan yang berbasis empiris. Melalui integrasi yang cermat antara aplikasi AI yang sensitif terhadap risiko dan pengawasan makroprudensial yang adaptif, otoritas keuangan dapat memandu transformasi keuangan menuju hasil yang tangguh dan berkeadilan.

## 5.6 KESIMPULAN

Analisis yang dilakukan di seluruh volume ini menyoroti integrasi progresif kecerdasan buatan dan pembelajaran mesin ke dalam struktur sistem keuangan. Teknologi ini menawarkan perangkat yang semakin canggih untuk memodelkan kompleksitas, mengelola ketidakpastian, dan meningkatkan efisiensi operasional. Aplikasinya mencakup spektrum aktivitas keuangan yang luas, mulai dari optimalisasi portofolio hingga penilaian kredit, dan dari deteksi penipuan hingga analisis informasi terkait keberlanjutan. Namun, implementasinya bukannya tanpa tantangan, terutama dalam konteks yang dicirikan oleh asimetri regulasi, masalah etika, dan interdependensi sistemik.

Salah satu area pengembangan yang paling signifikan adalah interseksi antara pemodelan berbasis data dan keberlanjutan. Kapasitas perangkat algoritmik untuk mengintegrasikan indikator lingkungan, sosial, dan tata kelola ke dalam proses investasi dan penilaian risiko menghadirkan peluang baru untuk menyelaraskan tujuan keuangan dengan prioritas masyarakat yang lebih luas. Melalui analisis data terstruktur dan tidak terstruktur, sistem berbasis AI mendukung identifikasi risiko keberlanjutan yang material, memungkinkan penyusunan portofolio yang selaras dengan tujuan transisi, dan memfasilitasi pengembangan kerangka kerja pengungkapan baru. Kemampuan ini tidak hanya meningkatkan pemilihan investasi tetapi juga berkontribusi pada keselarasan yang lebih luas antara alokasi modal dan tujuan keberlanjutan jangka panjang.

Pergeseran ini tidak terbatas pada optimalisasi tingkat portofolio tetapi meluas ke arsitektur sistemik risiko keuangan. Mengintegrasikan keberlanjutan ke dalam model risiko memerlukan pemikiran ulang terhadap variabel input dan asumsi kelembagaan. Dimensi ESG, jika diperlakukan secara dinamis dan kontekstual, dapat menjadi komponen penting dalam menilai paparan terhadap guncangan struktural jangka panjang, termasuk yang terkait dengan risiko iklim, transisi regulasi, dan kerentanan reputasi. Dalam konteks ini, kapasitas model pembelajaran mesin untuk menyerap, menimbang, dan memperbarui beragam sumber informasi menjadi faktor pendukung untuk evaluasi risiko yang lebih kuat dan berwawasan ke depan.

Transformasi yang dibawa oleh kecerdasan buatan juga memengaruhi desain dan koordinasi praktik manajemen risiko. Volatilitas, putaran umpan balik, dan konvergensi perilaku yang diperkenalkan oleh agen algoritmik memerlukan metode terbaru yang mampu mendeteksi sinyal awal ketidakstabilan dan mengoordinasikan respons di seluruh tingkat kelembagaan dan pengawasan. Dengan demikian, kerangka kerja manajemen risiko terpadu harus memperhitungkan tidak hanya kuantifikasi eksposur tetapi juga tata kelola model, garis keturunan data, dan efek penyebaran sistem pembelajaran di seluruh jaringan keuangan.

Implikasi lebih lanjut adalah semakin relevannya teknologi pengawasan yang mampu memantau sistem algoritmik dalam skala besar. Sebagaimana dibahas dalam Bab 4, lembaga publik mulai menerapkan infrastruktur bertenaga AI untuk deteksi anomali, pelacakan risiko sistemik, dan pengawasan waktu nyata. Perkembangan ini menggambarkan bahwa tata kelola AI dalam keuangan bukan hanya masalah tanggung jawab tingkat perusahaan, tetapi juga merupakan domain kebijakan publik dan pengawasan kelembagaan yang terus berkembang.

Perkembangan keuangan berbasis AI di masa depan akan bergantung pada kapasitas lembaga, peneliti, dan regulator untuk merancang sistem yang tidak hanya kokoh secara teknis, tetapi juga transparan, adil, dan tangguh. Hal ini akan membutuhkan upaya berkelanjutan untuk menyelaraskan metodologi teknis dengan tujuan regulasi dan untuk menanamkan akuntabilitas algoritmik ke dalam praktik operasional dan sistemik. Seiring ekosistem keuangan semakin dibentuk oleh arsitektur komputasional, kebutuhan akan tata kelola yang koheren dan adaptif akan menjadi semakin penting.

Oleh karena itu, keuangan berkelanjutan dan manajemen risiko terintegrasi bukanlah dimensi perifer, melainkan komponen dasar bagi evolusi AI dalam keuangan yang bertanggung jawab. Kedua area ini, jika didekati secara bersama-sama, menyediakan kerangka kerja yang koheren untuk mengevaluasi manfaat maupun eksternalitas yang terkait dengan otomatisasi dan prediksi dalam pengambilan keputusan keuangan. Keduanya memungkinkan pergeseran dari model pengendalian reaktif ke antisipatif, dari metrik efisiensi yang sempit ke kriteria ketahanan yang lebih luas, dan dari kepatuhan statis ke akuntabilitas dinamis.

Secara paralel, kolaborasi interdisipliner diperlukan untuk memastikan bahwa kemajuan teknologi mendukung tujuan yang lebih luas, yaitu inklusi keuangan, integritas pasar, dan nilai sosial. Hal ini membutuhkan transparansi metodologis, standar etika bersama, dan reflektivitas kelembagaan lintas sektor. Konvergensi pemodelan keuangan, ilmu keberlanjutan, dan teori regulasi membuka jalan baru bagi penelitian yang mampu mengintegrasikan akurasi teknis dengan relevansi normatif.

Pada akhirnya, evolusi kecerdasan buatan dalam keuangan harus didekati sebagai tantangan teknologi sekaligus tata kelola. Dengan menangani dimensi operasional, etika, dan sistemik secara bersamaan, sektor keuangan dapat memanfaatkan perangkat-perangkat ini tidak hanya untuk meningkatkan kinerja dan efisiensi, tetapi juga untuk memperkuat stabilitas, transparansi, dan legitimasi dalam lanskap yang semakin padat data. Tugas ke depan terletak pada memastikan bahwa inovasi tidak hanya dipercepat tetapi juga diarahkan pada sistem keuangan yang adaptif, inklusif, dan akuntabel.

## DAFTAR PUSTAKA

- Aevoae, G. M., Andrieş, A. M., Ongena, S., & Sprincean, N. (2022). ESG and systemic risk. *Applied Economic*, 55(27), 3085–3109.
- Aggarwal, C. C. (2015). *Data mining: The textbook*. Springer.
- Ahmed, S., Alshater, M. M., El Ammari, A., & Hammami, H. (2022). Artificial intelligence and machine learning in finance: A bibliometric review. *Research in International Business and Finance*, 61, Article 101646.
- Albahra, S., Gorbett, T., Robertson, S., D'Aleo, G., Kumar, S. V. S., Ockunzzi, S., Lallo, D., Hu, B., & Rashidi, H. H. (2023). Artificial intelligence and machine learning overview in pathology & laboratory medicine: A general review of data preprocessing and basic supervised concepts. *Seminars in Diagnostic Pathology*, 40(2), 71–87.
- Albuquerque, R., Koskinen, Y., & Zhang, C. (2019). Corporate social responsibility and firm risk: Theory and empirical evidence. *Management Science*, 65(10), 4451–4469.
- Albuquerque, R., Koskinen, Y., Yang, S., & Zhang, C. (2020). Resiliency of environmental and social stocks: An analysis of the exogenous COVID-19 market crash. *The Review of Corporate Finance Studies*, 9(3), 593–621.
- Al-Hashedi, K. G., & Magalingam, P. (2021). Financial fraud detection applying data mining techniques: A comprehensive review from 2009 to 2019. *Computer Science Review*, 40, Article 100402.
- Alpaydin, E. (2021). *Machine learning*. The MIT press.
- Apergis, N., Poufinas, T., & Antonopoulos, A. (2022). ESG scores and cost of debt. *Energy Economics*, 112, Article 106186.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., Garcia, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable artificial intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115.
- Ashtiani, M., & Raahemi, B. (2023). Application of natural language processing in financial markets: A review. *Expert Systems with Applications*, 213, Article 118924.
- Aziz, S., & Dowling, M. (2019). Machine learning and AI for risk management. In T. Lynn, J. Mooney, P. Rosati, & M. Cummins (Eds.), *Disrupting finance*. (pp. 33–50). Palgrave Pivot, Cham.
- Bahoo, S., Goodell, J. W., Rhattat, R., & Shahid, S. (2025). Artificial Intelligence in economics research: What have we learned? What do we need to learn? *Journal of Economic*

*Surveys*. Advance online publication.

- Bai, Y., Gao, Y., Wan, R., Zhang, S., & Song, R. (2025). A review of reinforcement learning in financial applications. *Annual Review of Statistics and Its Application*, 12(1), 209–232.
- Bao, W., Yue, J., & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long short-term memory. *PLoS ONE*, 12(7), Article e0180944.
- Barocas, S., Hardt, M., & Narayanan, A. (2019). *Fairness and machine learning: Limitations and opportunities*. The MIT Press.
- Battiston, S., Farmer, J. D., Flache, A., Garlaschelli, D., Haldane, A. G., Heesterbeek, H., Hommes, C., Jaeger, C., May, R., & Scheffer, M. (2016). Complexity theory and financial regulation: Economic policy needs interdisciplinary network analysis and behavioral modeling. *Science*, 351(6275), 818–819.
- Bazarbash, M. (2019). FinTech in financial inclusion: Machine learning applications in assessing credit risk. *IMF Working Papers*, 2019(109).
- Becchetti, L., Ciciretti, R., & Hasan, I. (2015). Corporate social responsibility, stakeholder risk, and idiosyncratic volatility. *Journal of Corporate Finance*, 35, 297–309.
- Becchetti, L., Ciciretti, R., Dalò, A., & Herzel, S. (2015). Socially responsible and conventional investment funds: Performance comparison and the global financial crisis. *Applied Economics*, 47(25), 2541–2562.
- Belanche, D., Casaló, L. V., Flavián, C., & Schepers, J. (2014). Trust transfer in the continued usage of public e-services. *Information & Management*, 51(6), 627–640.
- Bennell, J. A., Crabbe, D., Thomas, S. H., & Gwilym, O. A. (2006). Modelling sovereign credit ratings: Neural networks versus ordered probit. *Expert Systems with Applications*, 30(3), 415–425.
- Berg, F., Koelbel, J. F., & Rigobon, R. (2022). Aggregate confusion: The divergence of ESG ratings. *Review of Finance*, 26(6), 1315–1344.
- Berg, T., Fuster, A., & Puri, M. (2021). *FinTech lending* (NBER Working Paper No. 29421). National Bureau of Economic Research.
- Biju, A. K. V. N., Thomas, A. S., & Thasneem, J. (2024). Examining the research taxonomy of artificial intelligence, deep learning & machine learning in the financial sphere — A bibliometric analysis. *Quality & Quantity*, 58(1), 849–878.
- Binns, R. (2018). Fairness in machine learning: Lessons from political philosophy. In S. A. Friedler & C. Wilson (Eds.), *Proceedings of the 1st Conference on Fairness, Accountability and Transparency* (pp. 149–159). PMLR.
- Binns, R. (2020). On the apparent conflict between individual and group fairness. In *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency* (pp. 514–524). Association for Computing Machinery.

- Birindelli, G., Ferretti, P., Intonti, M., & Iannuzzi, A. (2015). On the drivers of corporate social responsibility in banks: Evidence from an ethical rating model. *Journal of Management and Governance*, 19, 303–340.
- Boutaba, R., Salahuddin, M. A., Limam, N., Ayoubi, S., Shahriar, N., Estrada- Solano, F., & Caicedo, O. M. (2018). A comprehensive survey on machine learning for networking: Evolution, applications and research opportunities. *Journal of Internet Services and Applications*, 9(1), Article 16.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Brown, I., & Mues, C. (2012). An experimental comparison of classification algorithms for imbalanced credit scoring data sets. *Expert Systems with Applications*, 39(3), 3446–3453.
- Brunnermeier, M. K., & Pedersen, L. H. (2009). Market liquidity and funding liquidity. *The Review of Financial Studies*, 22(6), 2201–2238.
- Buckley, R. P., Arner, D. W., & Zetsche, D. A. (2023). *FinTech: Finance, technology and regulation*. Cambridge University Press.
- Bussmann, N., Giudici, P., Marinelli, D., & Papenbrock, J. (2021). Explainable machine learning in credit risk management. *Computational Economics*, 57(1), 203–216.
- Campbell-Verduyn, M., Goguen, M., & Porter, T. (2017). Big data and algorithmic governance: The case of financial practices. *New Political Economy*, 22(2), 219–236.
- Cao, L. (2022). AI in finance: Challenges, techniques, and opportunities. *ACM Computing Surveys*, 55(3), 1–38.
- Cartea, Á., Jaimungal, S., & Penalva, J. (2015). *Algorithmic and high-frequency trading*. Cambridge University Press.
- Castellano, R., Cini, F., & Ferrari, A. (2024a). Machine learning for ESG rating classification: An integrated replicable model with financial and systemic. In M. Corazza, F. Gannon, F. Legros, C. Pizzi, & V. Touzé (Eds.), *Mathematical and Statistical Methods for Actuarial Sciences and Finance: MAF2024* (pp. 87–92). Springer Cham.
- Castellano, R., Cini, F., & Ferrari, A. (2024b). Value creation and sustainable business model: Are ESG ratings a matter of class? *Annals of Operations Research*, Article 104434.
- Cerciello, M., Busato, F., & Taddeo, S. (2023). The effect of sustainable business practices on profitability. Accounting for strategic disclosure. *Corporate Social Responsibility and Environmental Management*, 30(2), 802–819.
- Chatterji, A. K., Durand, R., Levine, D. I., & Touboul, S. (2016). Do ratings of firms converge? Implications for managers, investors and strategy researchers. *Strategic Management Journal*, 37(8), 1597–1614.
- Chen, J., Wang, X., & Xu, X. (2022). GC-LSTM: Graph convolution embedded LSTM for

dynamic network link prediction. *Applied Intelligence*, 52, 7513–7528.

- Chen, L., Zhang, L., Huang, J., Xiao, H., & Zhou, Z. (2021). Social responsibility portfolio optimization incorporating ESG criteria. *Journal of Management Science and Engineering*, 6(1), 75–85.
- Chowdhury, S., Dey, P., Joel-Edgar, S., Bhattacharya, S., Rodriguez-Espindola, O., Abadie, A., & Truong, L. (2023). Unlocking the value of artificial intelligence in human resource management through AI capability framework. *Human Resource Management Review*, 33(1), Article 100899.
- Christensen, H. B., Hail, L., & Leuz, C. (2021). Mandatory CSR and sustainability reporting: Economic analysis and literature review. *Review of Accounting Studies*, 26(3), 1176–1248.
- Cini, F., & Ferrari, A. (2025). Towards the estimation of ESG ratings: A machine learning approach using balance sheet ratios. *Research in International Business and Finance*, 73(Part B), Article 102653.
- Clementino, E., & Perkins, R. (2021). How do companies respond to environmental, social and governance (ESG) ratings? Evidence from Italy. *Journal of Business Ethics*, 171(2), 379–397.
- Corbett-Davies, S., Pierson, E., Feller, A., Goel, S., & Huq, A. (2017). Algorithmic decision making and the cost of fairness. In *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 797–806). Association Computing Machinery.
- Cowgill, B., Dell'Acqua, F., Deng, S., Hsu, D., Verma, N., & Chaintreau, A. (2020). Biased programmers? Or biased data? A field experiment in operationalizing AI ethics. In *Proceedings of the 21st ACM Conference on Economics and Computation* (pp. 679–681). Association for Computing Machinery.
- D'Errico, M., Battiston, S., Peltonen, T., & Scheicher, M. (2018). How does risk flow in the credit default swap market? *Journal of Financial Stability*, 35, 53–74.
- Das, S., Stanton, R., & Wallace, N. (2023). Algorithmic fairness. *Annual Review of Financial Economics*, 15(1), 565–593.
- Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116.
- de Lange, P. E., Melsom, B., Vennerød, C. B., & Westgaard, S. (2022). Explainable AI for credit assessment in banks. *Journal of Risk and Financial Management*, 15(12), Article 556.
- Demajo, L. M., Vella, V., & Dingli, A. (2020). Explainable ai for interpretable credit scoring. *Computer Science & Information Technology*, 185–203. <https://doi.org/10.48550/arXiv.2012.03749>
- Deng, Y., Bao, F., Kong, Y., Ren, Z., & Dai, Q. (2016). Deep direct reinforcement learning for

financial signal representation and trading. *IEEE Transactions on Neural Networks and Learning Systems*, 28(3), 653–664.

- Díaz-Rodríguez, N., Del Ser, J., Coeckelbergh, M., de Prado, M. L., Herrera- Viedma, E., & Herrera, F. (2023). Connecting the dots in trustworthy Artificial Intelligence: From AI principles, ethics, and key requirements to responsible AI systems and regulation. *Information Fusion*, 99, Article 101896.
- El Hajj, M., & Hammoud, J. (2023). Unveiling the influence of artificial intelligence and machine learning on financial markets: A comprehensive analysis of AI applications in trading, risk management, and financial operations. *Journal of Risk and Financial Management*, 16(10), Article 434.
- Elliott, M., Golub, B., & Jackson, M. O. (2014). Financial networks and contagion. *American Economic Review*, 104(10), 3115–3153.
- European Commission. (2021). *Proposal for a Regulation laying down harmonised rules on artificial intelligence (Artificial Intelligence Act) and amending certain Union legislative acts* (COM(2021) 206 final).
- Financial Stability Board (FSB). (2017). *Artificial intelligence and machine learning in financial services: Market developments and financial stability implications*.
- Fiordelisi, F., Ricci, O., & Santilli, G. (2023). Environmental engagement and stock price crash risk: Evidence from the European banking industry. *International Review of Financial Analysis*, 88, Article 102689.
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669.
- Frost, J., Gambacorta, L., Huang, Y., Shin, H. S., & Zbinden, P. (2019). BigTech and the changing structure of financial intermediation. *Economic Policy*, 34(100), 761–799.
- Fuster, A., Goldsmith-Pinkham, P., Ramadorai, T., & Walther, A. (2019). Predictably unequal? The effects of machine learning on credit markets. *The Journal of Finance*, 77(1), 5–47.
- Gabor, D., & Brooks, S. (2020). The digital revolution in financial inclusion: International development in the fintech era. In K. Bayliss, B. Fine, & M. Robertson (Eds.), *Material cultures of financialisation* (pp. 69–82). Routledge.
- Gai, P., & Kapadia, S. (2010). Contagion in financial networks. In *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 466(2120), 2401–2423.
- Gai, P., Haldane, A., & Kapadia, S. (2011). Complexity, concentration and contagion. *Journal of Monetary Economics*, 58(5), 453–470.
- Garcia, D., & Schweitzer, F. (2015). Social signals and algorithmic trading of Bitcoin. *Royal Society Open Science*, 2(9), Article 150288.

- Gavrilakis, N., & Floros, C. (2024). Volatility and herding bias on ESG Leaders' portfolios performance. *Journal of Risk and Financial Management*, 17(2), Article 77.
- Gibson Brandon, R., Krueger, P., & Mitali, S. F. (2020). *The sustainability footprint of institutional investors: ESG driven price pressure and performance* (Swiss Finance Institute Research Paper No. 17-05).
- Goodell, J. W., Kumar, S., Lim, W. M., & Pattnaik, D. (2021). Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. *Journal of Behavioral and Experimental Finance*, 32, Article 100577.
- Hardt, M., Price, E., & Srebro, N. (2016). Equality of opportunity in supervised learning. In the *Proceedings of the 30th Conference on Neural Information Processing Systems (NIPS 2016)* (pp. 3315–3323).
- Hassija, V., Chamola, V., Mahapatra, A., Singal, A., Goel, D., Huang, K., Scardapane, S., Spinelli, I., Mahmud, M., & Hussain, A. (2024). Interpreting black-box models: A review on explainable artificial intelligence. *Cognitive Computation*, 16(1), 45–74.
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2017). Deep learning for finance: Deep portfolios. *Applied Stochastic Models in Business and Industry*, 33(1), 3–12.
- Henisz, W. J., & McGlinch, J. (2019). ESG, material credit events, and credit risk. *Journal of Applied Corporate Finance*, 31(2), 105–117.
- Herm, L.-V., Janiesch, C., Helm, A., Imgrund, F., Hofmann, A., & Winkelmann, A. (2023). A framework for implementing robotic process automation projects. *Information Systems and e-Business Management*, 21, 1–35.
- Herman, D., Googin, C., Liu, X., Galda, A., Safro, I., Sun, Y., Pistoia, M., & Alexeev, Y. (2022). *A survey of quantum computing for finance*.
- Hoffmann, A. L. (2019). Where fairness fails: Data, algorithms, and the limits of antidiscrimination discourse. *Information, Communication & Society*, 22(7), 900–915.
- Hummer, W., Muthusamy, V., Rausch, T., Dube, P., & El Maghraoui, K. (2019). ModelOps: Cloud-based lifecycle management for reliable and trusted AI. In *Proceedings of the 2019 IEEE International Conference on Cloud Engineering (IC2E)* (pp. 110–120). IEEE.
- Jin, W., Du, H., Zhao, B., Tian, X., Shi, B., & Yang, G. (2025). *A comprehensive survey on multi-agent cooperative decision-making: Scenarios, approaches, challenges and perspectives*.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260.
- Kamiran, F., & Calders, T. (2012). Data preprocessing techniques for classification without discrimination. *Knowledge and Information Systems*, 33(1), 1–33.

- Kasy, M., & Abebe, R. (2021). Fairness, equality, and power in algorithmic decision-making. In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency* (pp. 576–586). Association for Computing Machinery.
- Khandani, A. E., Kim, A. J., & Lo, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance*, 34(11), 2767–2787.
- Kleinberg, J., Mullainathan, S., & Raghavan, M. (2016). Inherent trade-offs in the fair determination of risk scores. In C. H. Papadimitrou (Ed.), *Proceedings of Innovations in Theoretical Computer Science (ITCS)*, Article 43. LIPICs.
- Korteling, J. H., van de Boer-Visschedijk, G. C., Blankendaal, R. A., Boonekamp, R. C., & Eikelboom, A. R. (2021). Human-versus artificial intelligence. *Frontiers in Artificial Intelligence*, 4, Article 622364.
- Kotsantonis, S., & Serafeim, G. (2019). Four things no one will tell you about ESG data. *Journal of Applied Corporate Finance*, 31(2), 50–58.
- Kou, G., Chao, X., Peng, Y., Alsaadi, F. E., & Herrera-Viedma, E. (2019). Machine learning methods for systemic risk analysis in financial sectors. *Technological and Economic Development of Economy*, 25(5), 716–742.
- Krauss, C., Do, X. A., & Huck, N. (2017). Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research*, 259(2), 689–702.
- Lakhchini, W., Wahabi, R., & El Kabbouri, M. (2022). Artificial intelligence & machine learning in finance: A literature review. *International Journal of Accounting, Finance, Auditing, Management and Economics*, 3(6–1), 437–455.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Lessmann, S., Baesens, B., Seow, H.-V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, 247(1), 124–136.
- Li, Y., Wang, S., Ding, H., & Chen, H. (2023). Large language models in finance: A survey. In *Proceedings of the fourth ACM international conference on AI in finance* (pp. 374–382). Association for Computing Machinery.
- Lieto, A., Bhatt, M., Oltramari, A., & Vernon, D. (2018). The role of cognitive architectures in general artificial intelligence. *Cognitive Systems Research*, 48, 1–3.
- Lillo, F., & Valdés, R. (2016). Dynamics of financial markets and transaction costs: A graph-based study. *Research in International Business and Finance*, 38, 455–465.
- Liu, Y., Wu, H., Wang, J., & Long, M. (2022). Non-stationary transformers: Exploring the stationarity in time series forecasting. *Advances in Neural Information Processing Systems*, 35, 9881–9893.

- Lu, Y. (2019). Artificial intelligence: A survey on evolution, models, applications and future trends. *Journal of Management Analytics*, 6(1), 1–29.
- Maple, C., Szpruch, L., Epiphaniou, G., Staykova, K., Singh, S., Penwarden, W., Wen, Y., Wang, Z., Hariharan, J., & Avramovic, P. (2023). *The AI revolution: Opportunities and challenges for the finance sector*.
- Markauskaite, L., Marrone, R., Poquet, O., Knight, S., Martinez-Maldonado, R., Howard, S., Tondeur, J., De Laat, M., Buckingham Shum, S., Gašević, D., Siemens, G. (2022). Rethinking the entwinement between artificial intelligence and human learning: What capabilities do learners need for a world with AI? *Computers and Education: Artificial Intelligence*, 3, Article 100056.
- Mashrur, A., Luo, W., Zaidi, N. A., & Robles-Kelly, A. (2020). Machine learning for financial risk management: A survey. *IEEE Access*, 8, 203203–203223.
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys*, 54(6), 1–35.
- Molnar, C. (2022). *Interpretable machine learning: A guide for making black box models explainable*. Leanpub.
- Moodaley, W., & Telukdarie, A. (2023). Greenwashing, sustainability reporting, and artificial intelligence: A systematic literature review. *Sustainability*, 15(2), Article 1481.
- Newell, A. (1983). Intellectual issues in the history of artificial intelligence. In F. Machlup & U. Mansfield (Eds.), *Offprints from: The study of information: interdisciplinary messages* (pp. 187–227).
- Ozbayoglu, A. M., Gudelek, M. U., & Sezer, O. B. (2020). Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, Article 106384.
- Pástor, L., Stambaugh, R. F., & Taylor, L. A. (2021). Sustainable investing in equilibrium. *Journal of Financial Economics*, 142(2), 550–571.
- Pessach, D., & Shmueli, E. (2022). A review on fairness in machine learning. *ACM Computing Surveys*, 55(3), 1–44.
- Raji, I. D., Smart, A., White, R. N., Mitchell, M., Gebru, T., Hutchinson, B., Smith-Loud, J., Theron, D., & Barnes, P. (2020). Closing the AI accountability gap: Defining an end-to-end framework for internal algorithmic auditing. In *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency* (pp. 33–44). Association for Computing Machinery.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why should I trust you?”: Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1135–1144). Association for Computing Machinery.
- Rouf, N., Malik, M. B., Arif, T., Sharma, S., Singh, S., Aich, S., & Kim, H.-C. (2021). Stock

- market prediction using machine learning techniques: A decade survey on methodologies, recent developments, and future directions. *Electronics*, 10(21), Article 2717.
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206–215.
- Russell, S., & Norvig, P. (2010). *Artificial intelligence: A modern approach* (3rd ed.). Prentice Hall.
- Saha, S., Gao, J., & Gerlach, R. (2022). A survey of the application of graph-based approaches in stock market analysis and prediction. *International Journal of Data Science and Analytics*, 14(1), 1–15.
- Sarker, I. H. (2022). AI-based modeling: Techniques, applications and research issues towards automation, intelligent and smart systems. *SN Computer Science*, 3(2),
- Schmitt, M. (2022). *Deep learning vs. gradient boosting: Benchmarking state-of-the-art machine learning algorithms for credit scoring*.
- Schoenmaker, D., & Schramade, W. (2018). *Principles of sustainable finance*. Oxford University Press.
- Selbst, A. D., Boyd, D., Friedler, S. A., Venkatasubramanian, S., & Vertesi, J. (2019). Fairness and abstraction in sociotechnical systems. In *Proceedings of the Conference on Fairness, Accountability, and Transparency* (pp. 59–68). Association for Computing Machinery.
- Shah, J., Vaidya, D., & Shah, M. (2022). A comprehensive review on multiple hybrid deep learning approaches for stock prediction. *Intelligent Systems with Applications*, 16, Article 200111.
- Sironi, P. (2016). *FinTech innovation: from robo-advisors to goalbased investing and gamification*. John Wiley & Sons.
- Sun, S., Wang, R., & An, B. (2023). Reinforcement learning for quantitative trading. *ACM Transactions on Intelligent Systems and Technology*, 14(3), 1–29.
- Sutton, R. S., and Barto, A. G. (2018). *Reinforcement Learning: An Introduction* (2nd ed.), Cambridge, MA: MIT Press.
- Truant, E., Borlatto, E., Crocco, E., & Bhatia, M. (2023). ESG performance and technological change: Current state-of-the-art, development and future directions. *Journal of Cleaner Production*, 429, 139493.
- Vernon, D., & Furlong, D. (2007). Philosophical foundations of AI. In *50 Years of Artificial Intelligence: Essays Dedicated to the 50th Anniversary of Artificial Intelligence* (pp. 53–62). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Wang, Y., Albrecht, C. M., Braham, N. A. A., Mou, L., & Zhu, X. X. (2022). Self-supervised

learning in remote sensing: A review. *IEEE Geoscience and Remote Sensing Magazine*, 10(4), 213-247. 10.1109/MGRS.2022.3198244

- Weber, P., Carl, K. V., & Hinz, O. (2024). Applications of explainable artificial intelligence in finance — A systematic review of finance, information systems, and computer science literature. *Management Review Quarterly*, 74(2), 867–907.
- Wei, R., & Pardo, C. (2022). Artificial intelligence and SMEs: How can B2B SMEs leverage AI platforms to integrate AI technologies? *Industrial Marketing Management*, 107, 466–483.
- Werder, K., Ramesh, B., & Zhang, R. (2022). Establishing data provenance for responsible artificial intelligence systems. *ACM Transactions on Management Information Systems (TMIS)*, 13(2), 1–23.
- Whelan, T., Atz, U., Van Holt, T., & Clark, C. (2021). *ESG and financial performance: Uncovering the relationship by aggregating evidence from 1,000+ studies plus studies published between 2015–2020*. NYU Stern Center for Sustainable Business.
- Xu, J. (2024). *AI in ESG for financial institutions: An industrial survey*.
- Yeung, K. (2020). Recommendation of the council on artificial intelligence (OECD). *International legal materials*, 59(1), 27-34.
- Zetsche, D. A., Buckley, R. P., Arner, D. W., & Barberis, J. N. (2017). From FinTech to TechFin: The regulatory challenges of data-driven finance. *New York University Journal of Law and Business*. Advance online publication.
- Zhang, A. Y., & Zhang, J. H. (2024). Renovation in environmental, social and governance (ESG) research: The application of machine learning. *Asian Review of Accounting*, 32(4), 554–572.
- Zhang, B. H., Lemoine, B., & Mitchell, M. (2018). Mitigating unwanted biases with adversarial learning. In *Proceedings of the 2018 AAAI/ACM Conference on AI, Ethics, and Society* (pp. 335–340). Association for Computing Machinery.
- Zhu, H., Vigrén, O., & Söderberg, I. L. (2024). Implementing artificial intelligence empowered financial advisory services: A literature review and critical research agenda. *Journal of Business Research*, 174, 114494.

# AI & ML

## DI BIDANG KEUANGAN :

Mengatasi Masalah Kompleks dan Aplikasi Lingkungan,  
Sosial dan Tatakelola (ESG)

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

### BIODATA PENULIS



Penulis memiliki berbagai disiplin ilmu yang diperoleh dari Universitas Diponegoro (UNDIP) Semarang. dan dari Universitas Kristen Satya Wacana (UKSW) Salatiga. Disiplin ilmu itu antara lain teknik elektro, komputer, manajemen dan ilmu sosiologi. Penulis memiliki pengalaman kerja pada industri elektronik dan sertifikasi keahlian dalam bidang Jaringan Internet, Telekomunikasi, Artificial Intelligence, Internet Of Things (IoT), Augmented Reality (AR), Technopreneurship, Internet Marketing dan bidang pengolahan dan analisa data (komputer statistik).

Penulis adalah pendiri dari Universitas Sains dan Teknologi Komputer (Universitas STEKOM ) dan juga seorang dosen yang memiliki Jabatan Fungsional Akademik Lektor Kepala (Associate Professor) yang telah menghasilkan puluhan Buku Ajar ber ISBN, HAKI dari beberapa karya cipta dan Hak Paten pada produk IPTEK. Sejak tahun 2023 penulis tercatat sebagai Dosen luar biasa di Fakultas Ekonomi & Bisnis (FEB) Universitas Diponegoro Semarang. Penulis juga terlibat dalam berbagai organisasi profesi dan industri yang terkait dengan dunia usaha dan industri, khususnya dalam pengembangan sumber daya manusia yang unggul untuk memenuhi kebutuhan dunia kerja secara nyata.



YAYASAN PRIMA AGUS TEKNIK

#### PENERBIT :

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

ISBN 978-634-7227-62-1 (PDF)



9

786347

227621