

BUKU MONOGRAF

**Inovasi Pemodelan Prediksi Saham dengan
CNN-BigRU dan Attention Untuk Ketepatan
Kepuasan Berinvestasi**



**Ibnu Rasyid Munthe, ST., M.Kom, Bhakti Helvi Rambe, SE., M.Si,
Shabrina Rasyid Munthe, S.Pd.I., MS, Selamat Subagio, S.Kom., M.Kom,
Rahmad Aditiya, Eko Firman Susilo, M.Pd**

Buku Monograph

**Inovasi Pemodelan Prediksi Saham dengan CNN-BiGRU
dan Attention Untuk Ketepatan Keputusan Berinvestasi**

BUKU MONOGRAFT INOVASI PEMODELAN PREDIKSI SAHAM DENGAN CNN-BIGRU DAN ATTENTION UNTUK KETEPATAN KEPUTUSAN BERINVESTASI

**Ibnu Rasyid Munthe, S.T., M.Kom
Bhakti Helvi Rambe, SE., M.Si
Shabrina Rasyid Munthe, S.Pd.I., MS
Selamat Subagio, S.Kom., M.Kom
Rahmad Aditiya
Eko Firman Susilo, M.Pd**



**BUKU MONOGRAFT INOVASI PEMODELAN PREDIKSI SAHAM DENGAN CNN-BIGRU
DAN ATTENTION UNTUK KETEPATAN KEPUTUSAN BERINVESTASI**

**Ibnu Rasyid Munthe, S.T., M.Kom
Bhakti Helvi Rambe, SE., M.Si
Shabrina Rasyid Munthe, S.Pd.I., MS
Selamat Subagio, S.Kom., M.Kom
Rahmad Aditiya
Eko Firman Susilo, M.Pd**

Editor :
Sahat Parulian Sitorus

Desain Cover :
Nurhasanah

Sumber :
<https://isbn.jndi.my.id/products/buku-monograft-inovasi-pemodelan-prediksi-saham-dengan-cnn-bigru-dan-attention-untuk-ketepatan-keputusan-berinvestasi>

Tata Letak :
Ida Royani Sitorus

Ukuran :
Jml hal judul 251, Jml hal isi naskah 243, Uk: 17x25 cm

ISBN :
978-643-04-2311-2

Cetakan Pertama :
06 Agustus 2025

Hak Cipta 2025, Pada Penulis
Isi diluar tanggung jawab percetakan

Copyright © 2025 by PT.JNDI
All Right Reserved

Hak cipta dilindungi undang-undang
Dilarang keras menerjemahkan, memfotokopi, atau
memperbanyak sebagian atau seluruh isi buku ini
tanpa izin tertulis dari Penerbit.

PENERBIT PT. JASA NIAGA DIGITAL INDONESIA
Jl. H. Maulana Link. VI. Labuhan Ruku, Talawi, Batu Bara, Sumatera Utara 21254
Telp/Wa : 082361274081
<https://isbn.jndi.my.id>
E-mail:office@jndi.my.id

PRAKATA

Pasar saham ibarat samudra luas yang gelombangnya tak henti bergolak—menyimpan peluang sekaligus risiko. Di balik fluktuasi harga yang tampak acak, tersembunyi pola yang hanya dapat diungkap oleh pendekatan analisis yang tepat. Berangkat dari keyakinan bahwa data menyimpan cerita dan prediksi yang akurat dapat menjadi kunci keputusan investasi, lahirlah buku monograf *"Inovasi Pemodelan Prediksi Saham dengan CNN-BiGRU dan Attention untuk Ketepatan Keputusan Berinvestasi"*.

Buku ini menyajikan perpaduan teori yang menggabungkan kekuatan *Convolutional Neural Network* (CNN) untuk mengolah pola spasial, *Bidirectional Gated Recurrent Unit* (BiGRU) untuk menangkap hubungan temporal, serta *Attention Mechanism* sebagai penentu fokus informasi. Kami berharap karya ini menjadi referensi bagi akademisi, praktisi pasar modal, maupun mahasiswa yang ingin memahami dan menerapkan teknologi cerdas untuk investasi yang lebih tepat dan strategis.

Rantauprapat, Agustus 2025

Tim Penulis

KATA PENGANTAR

Puji syukur kami panjatkan ke hadirat Tuhan Yang Maha Esa atas terselesaikannya buku monograf "*Inovasi Pemodelan Prediksi Saham dengan CNN-BiGRU dan Attention untuk Ketepatan Keputusan Berinvestasi*". Buku ini lahir dari dorongan untuk menghadirkan pendekatan mutakhir dalam memahami dinamika pasar saham yang semakin kompleks dan cepat berubah. Melalui kombinasi *Convolutional Neural Network* (CNN), *Bidirectional Gated Recurrent Unit* (BiGRU), dan *Attention Mechanism*, kami berupaya menawarkan solusi prediksi yang tidak hanya akurat secara teknis, tetapi juga relevan untuk pengambilan keputusan investasi yang strategis.

Terima kasih kami sampaikan kepada rekan-rekan peneliti, praktisi, mahasiswa, dan semua pihak yang telah memberi masukan, dukungan, serta inspirasi. Semoga buku ini bermanfaat sebagai referensi ilmiah, panduan praktis, dan pemicu lahirnya inovasi-inovasi baru di bidang teknologi keuangan di Indonesia.

Rantauprapat, Agustus 2025

Tim Penulis

DAFTAR ISI

PRAKATA	5
KATA PENGANTAR	6
DAFTAR ISI	7
Bab 1. Pendahuluan	9
Pasar Saham Dan Perannya Dalam Perekonomian Global.....	10
Tantangan dalam memahami dan memprediksi pergerakan harga saham	14
Perbedaan pendekatan konvensional dan teknologi modern.....	18
Peran teknologi cerdas meningkatkan ketepatan prediksi.....	21
Tujuan strategis pengembangan model tepat.....	25
Bab 2. Fondasi Pergerakan Harga Saham.....	29
Faktor ekonomi yang mempengaruhi tren harga	29
Faktor psikologis dan perilaku investor	34
Hubungan antara indikator teknikal dan dinamika harga	37
Pola siklus pasar dan volatilitas	40
Interaksi kompleks antar faktor penentu harga	43
Bab 3. Perbandingan Pendekatan Klasik dan Berbasis AI	47
Asumsi linear dalam pendekatan Klasik.....	47
Keterbatasan menghadapi data yang tidak stasioner	50
Kerentanan terhadap sinyal palsu dan Anomali	55
Algoritma berbasis Machine Learning dan Deep Learning	59
Keunggulan pendekatan modern.....	62
Bab 4. Arsitektur Deep Learning Untuk Data Time Series	67
Peran CNN dalam mengenali pola	67
Kemampuan GRU dalam memahami hubungan temporal.....	72
Keunggulan BiGRU dalam pemrosesan dua arah	81
Sinergi CNN dan BiGRU dalam model hibrid	86
Implementasi untuk data pasar saham multivariabel	91
Manfaat dan Tantangan Masukan Multikanal.....	96
Hubungan Bentuk Input dan Arsitektur Model	97
Aplikasi Lintas Domain.....	97
Bab 5. Penerapan Mekanisme Attention Model Hibrid	101
Prinsip kerja attention mechanism.....	101
Penekanan pada periode dan fitur	107
Visualisasi attention weights	113
Jenis-jenis mekanisme attention mechanisms	120
Pemilihan Jenis <i>Attention</i> Berdasarkan Kebutuhan.....	121

Integrasi dalam Model <i>Hybrid</i>	122
Manfaat dalam menghadapi kondisi pasar yang volatil.....	140
Bab 6. Pengolahan Data Pasar Saham	148
Karakteristik dan sumber data.....	148
Strategi pembersihan dan DataSet	155
Penyesuaian terhadap nilai outliers	164
Normalisasi dan standarisasi fitur	170
Teknik reduction	177
Bab 7. Rekayasa Fitur untuk Meningkatkan Kinerja Model.....	183
Pemilihan indikator teknikal	183
Moving average untuk menangkap tren	187
Pembuatan fitur lag untuk Historis	192
Pengurangan redundansi evaluasi fitur	196
Feature importance menggunakan feature weighting	199
Bab 8. Pelatihan Model CNN-BiGRU-Attention.....	202
Transformasi data mentah menjadi format sequence.....	202
Ekstraksi pola lokal dengan CNN	204
Temporal dengan BiGRU.....	211
Integrasi hybrid architectures sebelum attention	213
Pengaturan parameter dan teknik overfitting	215
Bab 9. Evaluasi Kinerja dan Interpretasi Hasil	218
Pemilihan metrik pengukuran ketepatan prediksi.....	218
Pemanfaatan Korelasi untuk menilai tren	220
Performa pada kondisi pasar.....	222
Performa pada periode pasar volatil	224
Bab 10. Prospek dan Pemanfaatan Model di Masa Depan.....	227
Integrasi data tidak Terstruktur.....	227
Pemanfaatan arsitektur deep learning terbaru.....	229
Adaptasi model untuk pasar dan instrumen keuangan lainnya.....	231
Penggunaan model dalam sistem pendukung keputusan investasi..	233
Arah pengembangan menuju prediksi real-time	235

Bab 1. Pendahuluan

Pasar Saham Dan Perannya Dalam Perekonomian Global

Pasar saham merupakan salah satu pilar utama dalam sistem keuangan modern dengan peranan penting bagi dinamika perekonomian global. Keberadaannya bukan hanya menjadi ajang pertemuan antara penjual dan pembeli saham, tetapi juga berfungsi sebagai sarana penghimpunan modal, penyaluran sumber daya, dan cerminan ekspektasi terhadap kondisi ekonomi di masa depan. Melalui mekanisme perdagangan efek, bursa saham menjadi tempat bagi perusahaan memperoleh modal jangka panjang, sekaligus memberikan peluang bagi investor untuk menanamkan modal dengan harapan mendapatkan keuntungan. Fungsi yang beragam ini menjadikan pasar saham sensitif terhadap perubahan kondisi ekonomi, kebijakan, dan sentimen masyarakat.

Struktur bursa saham seperti New York Stock Exchange (NYSE), London Stock Exchange (LSE), dan Bursa Efek Indonesia (BEI) menyediakan platform publik yang memungkinkan perusahaan melepas saham melalui penawaran umum perdana (IPO). Proses ini tidak hanya menghimpun dana dari masyarakat, tetapi juga mendorong peningkatan transparansi perusahaan melalui kewajiban pelaporan dan pengungkapan informasi secara berkala. Bagi investor, kesempatan ini menjadi jalan untuk memiliki bagian dari perusahaan, menerima pembagian keuntungan, dan meraih potensi kenaikan nilai saham.

A. Fungsi Penghimpunan Modal

Fungsi utama pasar saham adalah memfasilitasi penghimpunan modal (capital formation). Melalui penerbitan saham baru, perusahaan dapat mengakses dana segar untuk membiayai ekspansi, inovasi teknologi, atau restrukturisasi keuangan. Mobilisasi tabungan masyarakat ke dalam instrumen ekuitas ini meningkatkan efisiensi alokasi modal, karena investor dapat memilih instrumen sesuai profil risiko dan preferensi imbal hasil, sementara perusahaan memperoleh sumber dana yang sesuai dengan kebutuhan strategisnya (Alexander & Beegam, 2023).

Kapitalisasi pasar yang besar dan likuiditas tinggi menciptakan ekosistem yang mendukung kelancaran arus dana antar sektor. Misalnya, sektor teknologi di Amerika Serikat berkembang pesat berkat kemudahan akses ke pasar modal, yang memungkinkan pembiayaan riset dan pengembangan dalam skala besar. Efek berganda (multiplier effect) dari investasi ini kemudian merambat ke sektor lain, menciptakan lapangan kerja, meningkatkan daya beli, dan pada akhirnya mendorong pertumbuhan ekonomi nasional maupun global.

B. Fungsi Penemuan Harga (Price Discovery)

Selain penghimpunan modal, fungsi fundamental lain dari pasar saham adalah penemuan harga (price discovery). Melalui interaksi permintaan dan penawaran, harga saham merefleksikan informasi yang tersedia secara publik, termasuk laporan keuangan, prospek bisnis, kebijakan moneter, dan bahkan sentimen pasar yang bersumber dari berita atau media sosial (Chen et al., 2021). Mekanisme ini difasilitasi oleh sistem perdagangan seperti *continuous order-driven markets* atau *call auctions* yang memungkinkan harga terbentuk secara transparan dan efisien (Han et al., 2022).

Keberadaan derivatif dan instrumen turunan lainnya turut memperkaya proses penemuan harga, karena menyediakan sarana lindung nilai (hedging) dan spekulasi yang dapat mempengaruhi ekspektasi pelaku pasar. Dengan demikian, harga saham tidak hanya mencerminkan kinerja fundamental perusahaan, tetapi juga proyeksi kondisi makroekonomi dan risiko yang diantisipasi oleh investor.

C. Pasar Saham sebagai Barometer Ekonomi

Indeks saham seperti S&P 500, FTSE 100, Nikkei 225, atau Indeks Harga Saham Gabungan (IHSG) sering digunakan sebagai indikator kesehatan ekonomi. Kenaikan atau penurunan indeks mencerminkan perubahan agregat nilai perusahaan yang terdaftar, yang pada gilirannya dipengaruhi oleh pertumbuhan Produk Domestik Bruto (PDB), inflasi, tingkat suku bunga, dan kebijakan fiskal maupun moneter (Kaushik & Kumar, 2023). Penelitian menunjukkan bahwa gejolak kebijakan moneter Amerika Serikat, misalnya, dapat menimbulkan dampak signifikan terhadap pasar global, termasuk negara berkembang (Lastauskas & Minh, 2021).

Pergerakan indeks juga dipengaruhi oleh variabel makroekonomi lainnya seperti nilai tukar, neraca perdagangan, dan stabilitas politik (Zuhroh et al., 2021). Saat ekonomi menunjukkan tanda-tanda ekspansi, indeks saham cenderung menguat seiring optimisme investor. Sebaliknya, pada periode resesi atau krisis, indeks biasanya mengalami penurunan signifikan akibat aksi jual yang masif.

D. Integrasi Pasar dan Dampak Globalisasi

Sejak 2015, perkembangan pasar saham global semakin ditandai oleh integrasi lintas negara, inovasi teknologi, dan reformasi regulasi. Program seperti Shanghai Hong Kong Stock Connect memungkinkan

investor asing mengakses pasar Tiongkok secara langsung, meningkatkan likuiditas dan mempercepat integrasi harga lintas bursa (Lin et al., 2021). Integrasi ini berarti bahwa guncangan di satu pasar dapat dengan cepat menyebar ke pasar lain, memperbesar risiko sistemik sekaligus membuka peluang diversifikasi portofolio global.

Inovasi teknologi seperti perdagangan algoritmik (*algorithmic trading*) dan kontrak pintar (*smart contracts*) telah mengurangi biaya transaksi dan mempercepat eksekusi order (Bohyer & Hayajneh, 2023). Teknologi ini memungkinkan analisis data pasar secara real-time, deteksi pola, dan pengambilan keputusan otomatis yang responsif terhadap perubahan kondisi pasar. Namun, percepatan ini juga menimbulkan tantangan baru dalam hal stabilitas harga dan potensi volatilitas ekstrem.

E. Pengaruh Krisis Global

Pandemi COVID-19 menjadi contoh nyata bagaimana pasar saham bereaksi terhadap guncangan global. Pada awal 2020, pasar global mengalami penurunan tajam akibat ketidakpastian ekonomi dan gangguan rantai pasok internasional. Volatilitas yang tinggi mendorong regulator untuk melakukan penyesuaian kebijakan, sementara investor melakukan rebalancing portofolio secara masif (Amalia, 2022). Pasar kemudian berangsur pulih berkat stimulus fiskal dan moneter yang masif, tetapi pola perdagangan mengalami pergeseran, dengan meningkatnya partisipasi investor ritel dan penggunaan platform daring. Pengalaman tersebut menunjukkan bahwa pasar saham bukan hanya mencerminkan kondisi ekonomi, tetapi juga menjadi arena di mana ekspektasi dan psikologi kolektif diuji. Kecepatan reaksi terhadap berita dan peristiwa global menegaskan peran pasar saham sebagai cerminan dinamis dari sentimen dan proyeksi ekonomi.


Pasar saham berperan ganda sebagai sarana penghimpunan modal dan sebagai mekanisme penemuan harga yang efisien. Pergerakannya merefleksikan ekspektasi pelaku pasar terhadap masa depan ekonomi, yang dipengaruhi oleh interaksi kompleks antara faktor fundamental, kebijakan, dan sentimen global. Integrasi pasar modal internasional, kemajuan teknologi perdagangan, dan respons terhadap krisis global menunjukkan bahwa pasar saham merupakan entitas yang adaptif, tetapi juga rentan terhadap volatilitas dan risiko sistemik.

Tabel 1. Performa Tahunan Indeks Pasar Saham

Tahun	MSCI World	Nasdaq Composite	S&P 500	IHSG Indonesia
2015	−0.32	+5.73	−0.73	−12.13 %
2016	+8.15	+7.50	+9.54	+15.32 %
2017	+23.07	+28.24	+19.42	+19.99 %
2018	−8.20	−3.88	−6.24	−2.54 %
2019	+28.40	+35.23	+28.88	+1.70 %
2020	+16.50	+43.64	+16.26	−5.09 %
2021	+22.35	+21.39	+26.89	+10.08 %
2022	−17.73	−33.10	−19.44	+4.09 %
2023	+24.42	+43.42	+24.23	+6.16 %
2024	+19.19	+28.64	+23.31	−2.65 %

Tabel ini menampilkan return tahunan dari empat indeks pasar saham utama sepanjang periode 2015 hingga 2024, MSCI World (global), Nasdaq Composite (AS), S&P 500 (AS), dan IHSG (Indonesia). MSCI World menunjukkan fluktuasi kuat dengan pertumbuhan tinggi di 2017–2019 dan rebound di 2020–2021, namun mengalami penurunan tajam di 2018 dan 2022. Nasdaq Composite terlihat paling volatil, mencatat kenaikan luar biasa pada 2020 (+43.6 %) dan 2023 (+43.4 %), tetapi juga penurunan tajam di 2022 (−33.1 %). S&P 500, meskipun lebih stabil dibanding Nasdaq, tetap menunjukkan tren positif kuat dengan beberapa koreksi (2015, 2018, 2022). Periode 2016–2021 secara konsisten

menguat. IHSG (Indonesia) memperlihatkan variasi yang unik. Pasar Indonesia mengalami penurunan tajam pada 2015 (−12.1 %), rebound kuat di 2016–2017, kemudian penurunan moderat di 2018. Kinerja tahun 2019–2021 positif, diikuti dengan pertumbuhan rendah pada 2022–2023. Namun, pada 2024 terjadi koreksi kecil (−2.65 %), menunjukkan bahwa pasar domestik lebih tahan terhadap penurunan ekstrem dibandingkan global di beberapa tahun.



Gambar 1. Tren Perubahan Tahunan Indeks Saham Dunia.

Tantangan dalam memahami dan memprediksi pergerakan harga saham

Pergerakan harga saham di pasar modal dunia mencerminkan interaksi yang rumit antara faktor ekonomi dan psikologis yang terus berubah. Respons pasar tidak hanya bergantung pada kondisi fundamental seperti kinerja perusahaan, pertumbuhan ekonomi, atau kebijakan keuangan, tetapi juga pada persepsi, ekspektasi, dan emosi

pelaku pasar. Perubahan sentimen yang cepat dapat memicu lonjakan atau penurunan harga yang tajam.

Fenomena ini kian kompleks karena adanya sifat non-linear dalam perubahan imbal hasil. Pergeseran keadaan pasar dapat muncul secara tiba-tiba ketika keseimbangan penawaran dan permintaan terganggu. Ketidakseimbangan tersebut kerap menghasilkan penyesuaian harga yang tidak sebanding, menciptakan lonjakan besar. Situasi ini dapat diperparah oleh terbatasnya likuiditas dan gangguan dalam arus pesanan, yang memicu rangkaian reaksi berantai.

Struktur mikro pasar berperan besar dalam membentuk pola ini. Hubungan antara aliran pesanan, penyedia likuiditas, dan teknologi perdagangan menjadi saluran penyebaran perubahan harga. Guncangan dapat muncul akibat peristiwa eksternal seperti gejolak geopolitik, atau dari masalah internal seperti krisis likuiditas. Dalam jaringan perdagangan yang saling terhubung, tingkat keterkaitan antar pelaku pasar mempengaruhi seberapa besar dan cepat dampak menyebar.

Ketika terjadi ketidakstabilan, pergerakan harga antar negara atau sektor cenderung selaras. Tekanan di satu pasar dapat menjalar ke pasar lain melalui hubungan dagang, arus modal, atau perubahan persepsi risiko secara global. Saluran seperti perbedaan harga penawaran dan permintaan, serta kondisi buku pesanan, dapat menjadi jalur perpindahan tekanan antar instrumen atau pasar.

Pendekatan pemodelan mutakhir mengungkap adanya perbedaan respons likuiditas dan arus pesanan terhadap guncangan. Dampaknya, pola penyebaran antar aset atau pasar bisa berbeda-beda, membentuk variasi volatilitas. Hubungan jaringan global juga menunjukkan bahwa

pada periode ketidakpastian tinggi, risiko dapat berpindah antar kelas aset dan wilayah dengan cepat, kadang di luar dugaan.

Upaya memproyeksikan harga saham dalam lingkungan seperti ini memerlukan cara pandang yang mampu menangkap perubahan mendadak dan lonjakan volatilitas. Banyak pendekatan tradisional kesulitan menghadapi dinamika yang muncul akibat guncangan likuiditas atau perubahan perilaku investor. Gangguan dari aktivitas perdagangan berkecepatan tinggi dan ketidakseimbangan likuiditas jangka pendek menambah kerumitan, serta meningkatkan kemungkinan kesalahan proyeksi. Dalam sistem yang saling terhubung, kesalahan ini bisa diperbesar oleh efek limpahan yang tidak terduga.

Perpaduan faktor ekonomi, perilaku pelaku pasar, dan karakter teknis pasar modal mengharuskan penggunaan pendekatan yang luwes. Pemahaman yang utuh tentang bagaimana mekanisme mikro, keterkaitan global, dan reaksi pelaku pasar terhadap perubahan informasi saling mempengaruhi dapat membantu mengurangi risiko kesalahan proyeksi dan meningkatkan pemahaman terhadap dinamika harga yang bergerak cepat.

Tabel 2. Faktor Pendorong Volatilitas dan Dampaknya pada IHSG

Faktor Pendorong	Dampak pada Volatilitas IHSG
Inflasi	Meningkatkan volatilitas, karena inflasi tinggi bisa mendorong investor masuk ke pasar saham sebagai proteksi atau sebaliknya mengurangi daya beli dan menekan IHSG
Tingkat Suku Bunga	Umumnya suku bunga tinggi meningkatkan volatilitas. Ini terjadi karena investor beralih ke instrumen aman. suku bunga juga bisa menekan IHSG
Nilai Tukar Rupiah (kurs)	Fluktuasi khususnya pelemahan rupiah—menambah volatilitas IHSG. Dampak

	meliputi peningkatan biaya produksi dan menurunnya sentimen investor asing
Kondisi Pasar Global	Indeks saham global yang jatuh ikut mendorong volatilitas IHSG karena keterkaitan pasar global.
Sentimen Pasar & Politik Domestik	Ketidakpastian fiskal/moneter atau kebijakan pemerintah yang dianggap tidak kredibel dapat memicu volatilitas signifikan
Likuiditas & Volume Perdagangan	Volume perdagangan rendah atau spread lebar menyebabkan fluktuasi harga lebih tajam, sehingga meningkatkan volatilitas saham dan IHSG

Tabel di atas menyajikan berbagai faktor utama yang mempengaruhi tingkat volatilitas Indeks Harga Saham Gabungan (IHSG) di pasar modal Indonesia, beserta deskripsi dampaknya. Faktor-faktor ini mencerminkan dinamika ekonomi makro, kondisi global, serta karakteristik internal pasar saham. Inflasi menjadi salah satu pemicu utama volatilitas. Kenaikan inflasi dapat mendorong investor beralih ke saham sebagai bentuk lindung nilai, namun juga berpotensi menekan IHSG akibat turunnya daya beli masyarakat. Tingkat suku bunga turut memengaruhi arah pasar, kenaikan suku bunga biasanya mengalihkan dana ke instrumen yang lebih aman, sehingga mengurangi permintaan terhadap saham dan meningkatkan volatilitas. Nilai tukar rupiah yang melemah dapat memperbesar biaya produksi bagi emiten berbasis impor dan mengurangi minat investor asing, memicu fluktuasi tajam pada IHSG. Kondisi pasar global juga berperan signifikan—penurunan indeks utama dunia sering kali menular ke IHSG karena keterkaitan pasar internasional. Selain itu, sentimen pasar dan kondisi politik domestik memegang peranan penting. Ketidakpastian kebijakan fiskal dan moneter atau langkah pemerintah yang dinilai tidak kredibel dapat menimbulkan kepanikan dan pergerakan harga yang ekstrem. Faktor terakhir adalah

likuiditas dan volume perdagangan. pasar dengan likuiditas rendah atau spread harga yang lebar cenderung mengalami pergerakan harga lebih tajam, sehingga meningkatkan volatilitas.

Perbedaan pendekatan konvensional dan teknologi modern

Pendekatan konvensional dalam memahami dan memprediksi pergerakan harga saham dibangun di atas asumsi-asumsi sederhana yang mengandalkan keteraturan pola historis dan hubungan linear antar variabel. Dalam kerangka ini, pergerakan harga dipandang sebagai hasil dari keseimbangan antara penawaran dan permintaan yang dapat diperkirakan melalui indikator ekonomi makro, laporan keuangan, atau tren musiman. Model-model klasik seperti regresi linear, analisis teknikal berbasis pola grafik, dan pendekatan fundamental tradisional menjadi alat utama yang digunakan. Keunggulan metode ini terletak pada kesederhanaan dan kemampuannya memberikan gambaran yang mudah dipahami, namun keterbatasannya muncul ketika pasar menghadapi perubahan mendadak, dinamika non-linear, atau interaksi kompleks antar faktor yang tidak dapat direpresentasikan dengan baik oleh model statis.

Sementara itu, perkembangan teknologi modern telah mendorong transformasi signifikan dalam cara memodelkan dan memprediksi pasar. Kemampuan komputasi yang tinggi, ketersediaan data besar, dan kemajuan dalam pembelajaran mesin memungkinkan analisis terhadap pola yang kompleks, non-linear, dan adaptif. Teknologi ini tidak lagi hanya mengandalkan data historis sederhana, tetapi juga mampu memproses data real-time, mengintegrasikan informasi dari berbagai sumber seperti media sosial, berita global, dan indikator pasar lainnya. Pendekatan ini memanfaatkan model prediktif berbasis jaringan

saraf dalam, pemrosesan bahasa alami, dan algoritma optimasi canggih untuk mengidentifikasi hubungan tersembunyi yang sulit dideteksi oleh metode konvensional.

Perbedaan mendasar antara keduanya terlihat pada ketepatan dan ketahanan hasil prediksi. Pendekatan konvensional, dengan keterbatasan asumsi linear dan stasioner, cenderung kurang responsif terhadap perubahan struktural atau guncangan pasar yang tiba-tiba. Sebaliknya, teknologi modern dirancang untuk belajar dari data yang terus berkembang, menyesuaikan parameter secara dinamis, dan mengidentifikasi pola yang muncul dari interaksi kompleks antar variabel. Misalnya, hipotesis pasar inelastis menunjukkan bahwa reaksi terhadap ketidakseimbangan pasokan dan permintaan bersifat non-linear dan dapat memicu pergeseran rezim secara tiba-tiba. Teknologi modern mampu menangkap fenomena ini dengan memodelkan dinamika mikrostruktural, keterbatasan likuiditas, serta interaksi aliran pesanan.

Dalam kerangka mikrostruktur pasar, teknologi modern mampu memantau dan menganalisis hubungan antara penyedia likuiditas, aliran pesanan, dan algoritma perdagangan secara real-time. Hal ini memungkinkan deteksi dini terhadap pergeseran kondisi pasar dan penyebaran guncangan melalui jaringan perdagangan global. Penelitian berbasis jaringan menunjukkan bahwa saat terjadi ketidakstabilan, pergerakan harga cenderung tersinkronisasi antar pasar dan wilayah, memperkuat dampak guncangan. Teknologi modern, dengan kemampuannya memproses data kompleks dalam jumlah besar, memberikan keunggulan dalam memetakan dan memprediksi jalur penyebaran risiko ini.

Metode pemodelan berbasis operator integral Fourier, misalnya, telah digunakan untuk mengidentifikasi asimetri dalam respons likuiditas terhadap guncangan, sehingga dapat memperkirakan jalur penyebaran yang berbeda antar aset. Selain itu, teknik keterhubungan jaringan global membantu memetakan risiko lintas kelas aset dan batas geografis. Dengan dukungan komputasi modern, pemodelan semacam ini dapat dilakukan dengan kecepatan tinggi, memungkinkan respons yang lebih cepat terhadap perubahan pasar.

Kesalahan prediksi dalam pendekatan konvensional sering kali bersumber dari kegagalan menangkap dinamika non-linear dan transisi rezim. Model linear tidak memadai untuk mengantisipasi lonjakan volatilitas akibat guncangan likuiditas atau perubahan perilaku investor. Di sisi lain, teknologi modern memanfaatkan algoritma pembelajaran adaptif yang mampu memperbarui pemahaman terhadap struktur pasar secara berkelanjutan, sehingga mengurangi risiko kesalahan prediksi.

Faktor tambahan yang membedakan keduanya adalah kemampuan mengelola noise mikrostruktural. Perdagangan frekuensi tinggi dan ketidakseimbangan likuiditas sementara sering kali menjadi tantangan bagi model tradisional. Teknologi modern, melalui algoritma deteksi anomali dan pemfilteran sinyal canggih, dapat memisahkan sinyal pasar yang relevan dari gangguan sementara ini, meningkatkan akurasi prediksi.

Pergeseran menuju teknologi modern tidak hanya memengaruhi tingkat ketepatan, tetapi juga ketahanan hasil. Model yang adaptif terhadap kondisi pasar yang berubah memberikan stabilitas yang lebih baik dalam menghadapi ketidakpastian global. Integrasi teknologi seperti pemrosesan bahasa alami untuk mengukur sentimen investor atau

pembelajaran multitugas untuk memproyeksikan beberapa indikator sekaligus telah membuka peluang baru dalam memahami dinamika pasar.

Peran teknologi cerdas meningkatkan ketepatan prediksi

Pendekatan konvensional dalam pemodelan dan prediksi pasar keuangan telah lama menjadi landasan bagi banyak strategi investasi dan manajemen risiko. Teknik-teknik seperti autoregressive integrated moving average (ARIMA), regresi linear, dan model parametrik lainnya dirancang dengan asumsi linearitas dan Fluktuasi harga harian suatu saham di sekitar rata-rata tetap tanpa tren jangka panjang (kestasioneran) data. Asumsi ini menyederhanakan kompleksitas pasar dengan menganggap bahwa hubungan antara variabel bersifat stabil dan dapat diprediksi berdasarkan pola historis. Model semacam ini juga mengandalkan rekayasa fitur manual, di mana analis atau ekonom menentukan variabel-variabel yang dianggap relevan untuk menjelaskan dinamika pasar.

Meskipun memiliki keunggulan dalam hal transparansi dan interpretasi, pendekatan konvensional sering kali gagal menangkap fenomena non-linear yang menjadi ciri khas pergerakan harga di pasar modern. Fluktuasi mendadak, Kebijakan , dan klasterisasi volatilitas sering kali berada di luar jangkauan model linear. Dalam kondisi pasar yang dipengaruhi oleh ketidakseimbangan pasokan dan permintaan, keterbatasan likuiditas, dan perilaku investor yang dinamis, asumsi sederhana ini sering kali menghasilkan prediksi yang kurang akurat.

Perkembangan teknologi telah memunculkan pendekatan modern yang memanfaatkan kekuatan pembelajaran mesin dan jaringan

saraf dalam untuk memahami pola kompleks pada data keuangan. Arsitektur seperti long short-term memory (LSTM), convolutional neural networks (CNN), dan model berbasis Transformer memungkinkan sistem untuk mempelajari hubungan non-linear dan pola temporal langsung dari data mentah, tanpa memerlukan bentuk fungsi yang telah ditentukan sebelumnya. Hierarki lapisan non-linear ini memberikan kemampuan bagi model untuk mengekstraksi fitur-fitur yang bersifat hierarkis, mengidentifikasi interaksi variabel yang kompleks, dan menyesuaikan diri dengan perubahan struktural dalam data.

Keunggulan utama dari pendekatan modern adalah kemampuannya untuk mengakomodasi pergeseran rezim dan fenomena volatilitas yang tidak stasioner. Berbeda dengan model linear yang statis, model berbasis pembelajaran mesin mampu memperbarui representasinya seiring perubahan data, sehingga meningkatkan akurasi prediksi. Studi empiris menunjukkan bahwa model non-linear sering kali memberikan kinerja yang lebih baik dalam tugas peramalan harga, estimasi volatilitas, dan penilaian risiko, karena mampu menangkap ketergantungan temporal yang rumit dan korelasi silang antar aset.

Namun, kompleksitas yang tinggi pada model modern juga membawa tantangan baru. Kemampuan untuk menyesuaikan diri dengan pola data yang kompleks dapat menyebabkan overfitting, terutama ketika rasio sinyal terhadap noise dalam data keuangan relatif rendah. Overfitting mengurangi kemampuan generalisasi model, sehingga prediksi untuk data di luar sampel dapat menjadi kurang andal. Oleh karena itu, praktik regulasi seperti penggunaan dropout, regularisasi L2, dan validasi silang menjadi bagian integral dari penerapan model modern

untuk memastikan keseimbangan antara kompleksitas dan kemampuan generalisasi.

Selain itu, integrasi data berfrekuensi tinggi dan data alternatif—seperti berita keuangan, media sosial, dan indikator makroekonomi real-time—meningkatkan potensi model modern untuk memahami sentimen pasar dan mengantisipasi perubahan harga. Analisis sentimen berbasis pemrosesan bahasa alami (NLP) memungkinkan model untuk menggabungkan informasi kualitatif dengan data kuantitatif, menciptakan gambaran pasar yang lebih holistik.

Pergeseran dari pendekatan linear menuju pembelajaran non-linear juga mempengaruhi cara pelaku pasar dalam mengelola risiko. Dengan memanfaatkan jaringan konektivitas antar pasar dan instrumen, model modern dapat mengidentifikasi jalur transmisi risiko yang kompleks. Misalnya, teknik berbasis jaringan dapat mendeteksi sinkronisasi pergerakan harga di berbagai pasar selama periode tekanan, serta melacak penyebaran guncangan melalui saluran mikrostruktural seperti spread bid-ask dan dinamika buku pesanan.

Pemodelan berbasis operator integral Fourier juga memberikan wawasan tambahan dengan mengungkap asimetri dalam respons likuiditas terhadap guncangan. Hal ini memungkinkan identifikasi jalur propagasi yang berbeda untuk aset atau pasar tertentu, yang dapat dimanfaatkan dalam strategi lindung nilai atau diversifikasi portofolio. Dengan demikian, teknologi modern tidak hanya meningkatkan akurasi prediksi, tetapi juga memperkaya pemahaman terhadap dinamika pasar yang kompleks.

Perbandingan antara pendekatan konvensional dan modern menunjukkan bahwa meskipun pendekatan lama lebih sederhana dan

mudah diinterpretasikan, keterbatasannya dalam menangkap dinamika kompleks membuatnya kurang adaptif terhadap kondisi pasar yang berubah cepat. Sebaliknya, pendekatan modern menawarkan fleksibilitas dan kapasitas pembelajaran yang lebih tinggi, tetapi memerlukan pengelolaan risiko model yang cermat untuk menghindari jebakan kompleksitas yang berlebihan.

Keseimbangan antara kedua pendekatan ini sering kali menjadi solusi praktis di lapangan. Banyak praktisi menggabungkan model konvensional dan modern dalam kerangka hibrida, memanfaatkan transparansi dan interpretabilitas model linear bersama kekuatan representasional model non-linear. Strategi ini tidak hanya meningkatkan akurasi prediksi, tetapi juga memberikan kepercayaan kepada pengambil keputusan melalui penjelasan yang lebih jelas tentang faktor-faktor yang memengaruhi hasil.

Tabel 3. Ringkasan Studi Kinerja AI pada Data Pasar

Penelitian	Pendekatan	Data Pasar	Temuan Utama
Chen & Hu (2022)	LSTM hibrida	Indeks saham China dan AS	Meningkatkan akurasi peramalan volatilitas dibanding model tradisional
Lim & Zohren (2021)	Deep learning berbagai arsitektur	Deret waktu keuangan global	Mampu menangkap non-linearitas dan pola temporal kompleks
Lin (2024)	Model berbasis Transformer	Data keuangan multinasional	Efektif untuk prediksi jangka pendek dan penyesuaian terhadap perubahan struktural
Sethy & Tripathy (2024)	Estimasi likuiditas berbasis jaringan	Pasar saham India	Mengidentifikasi jalur propagasi risiko dan hubungan antar aset

Gabaix & Koijen (2021)	Hipotesis pasar inelastis	Berbagai pasar global	Menjelaskan lonjakan harga akibat ketidakseimbangan pasokan-permintaan
------------------------	---------------------------	-----------------------	--

Tabel ini memberikan pemetaan pada lima studi utama yang membahas penerapan kecerdasan buatan dalam memahami, memodelkan, dan memproyeksikan pergerakan pasar keuangan. Setiap entri memuat informasi inti seperti identitas studi, teknik atau algoritme yang digunakan, jenis data pasar yang dianalisis, serta temuan pokok yang dicapai. Metode yang tercantum—mulai dari LSTM hibrida, arsitektur deep learning multivariasi, model berbasis Transformer, pendekatan estimasi likuiditas berbasis jaringan, hingga kerangka hipotesis pasar inelastis—mencerminkan keberagaman solusi AI yang dirancang untuk melampaui keterbatasan model linear konvensional. Pendekatan ini memungkinkan identifikasi pola non-linear, pengenalan dinamika temporal yang kompleks, pemetaan jalur transmisi risiko, serta pemahaman mekanisme propagasi guncangan lintas pasar.

Tujuan strategis pengembangan model tepat

Pengembangan model prediksi yang akurat memiliki peran penting dalam menyelaraskan keluaran dengan dinamika pasar yang terus berubah. Tujuan utamanya adalah menghadirkan proyeksi yang tidak hanya mendekati kondisi nyata, tetapi juga memberikan wawasan yang bermanfaat bagi berbagai pemangku kepentingan. Kejelasan manfaat dari hasil yang dihasilkan menjadi faktor penentu dalam mendorong adopsi secara luas di berbagai sektor, terutama di bidang keuangan, perdagangan, dan manajemen risiko.

Peningkatan ketepatan proyeksi mampu mengurangi ketidakpastian yang dihadapi oleh pelaku pasar. Investor, manajer

portofolio, dan eksekutif perusahaan mendapatkan keuntungan langsung berupa alokasi modal yang lebih tepat, perencanaan likuiditas yang lebih efisien, dan penyusunan panduan laba yang lebih akurat. Model prediksi yang disertai pengukuran risiko yang canggih memungkinkan penilaian yang lebih tepat terhadap risiko kredit, pasar, dan operasional. Hasilnya adalah keputusan strategis yang didukung oleh dasar kuantitatif yang solid.

Bagi manajer rantai pasok dan eksekutif operasional, ketepatan peramalan permintaan dan arus kas menjadi kunci untuk menjaga efisiensi biaya produksi dan mengoptimalkan persediaan. Hal ini juga mendukung keberlanjutan bisnis melalui pengurangan pemborosan dan peningkatan ketahanan operasional. Sementara itu, regulator dan auditor eksternal mengandalkan akurasi proyeksi untuk menilai keandalan laporan keuangan dan pengungkapan risiko, sehingga memperkuat transparansi dan kepercayaan pasar.

Manfaat strategis lainnya adalah peningkatan efektivitas pengelolaan risiko. Proyeksi yang presisi memungkinkan deteksi dini potensi gangguan dan mendukung langkah mitigasi yang proaktif. Perusahaan dapat menerapkan strategi lindung nilai secara dinamis, membangun cadangan likuiditas, serta melakukan pemantauan risiko kredit secara real-time. Strategi ini membantu mengurangi dampak guncangan pasar yang tak terduga dan menjaga kestabilan kinerja jangka panjang.

Pemanfaatan teknologi cerdas, seperti pembelajaran mendalam dan inovasi di bidang fintech, memperluas kemampuan model untuk menyesuaikan struktur modal dan profil risiko secara tepat waktu. Integrasi teknologi ini menghasilkan efisiensi operasional yang lebih tinggi

dan mengurangi biaya modal yang terkait dengan risiko. Dampaknya tidak hanya terlihat dalam perbaikan jangka pendek, tetapi juga dalam keberlanjutan pertumbuhan dan ketahanan perusahaan.

Indikator keberhasilan dari model prediksi yang unggul dapat diukur melalui penurunan signifikan pada tingkat kesalahan proyeksi, peningkatan indikator kinerja keuangan, serta perbaikan rasio imbal hasil yang disesuaikan dengan risiko. Dalam praktiknya, penerapan analitik prediktif yang maju terbukti menghasilkan rotasi persediaan yang lebih konsisten, penurunan biaya operasional, dan keputusan alokasi modal yang lebih akurat. Dampak ini memberikan landasan kuat bagi evaluasi kinerja internal dan memperkuat keyakinan pihak eksternal terhadap prospek perusahaan.

Dengan demikian, tujuan strategis dari pengembangan model yang tepat bukan hanya sekadar menghadirkan angka proyeksi, tetapi menciptakan alat yang dapat memandu arah kebijakan, memperkuat ketahanan organisasi, dan membuka peluang baru di tengah persaingan global. Penggabungan wawasan kuantitatif dengan penerapan teknologi modern memastikan bahwa setiap keputusan yang diambil berakar pada pemahaman yang mendalam terhadap realitas pasar, sehingga menghasilkan manfaat yang nyata bagi seluruh pemangku kepentingan.

Tabel 4. Manfaat bagi Investor, Manajer Aset, dan Regulator

Pemangku Kepentingan	Manfaat Utama	Dampak Strategis
Investor	Perencanaan modal yang lebih efisien, peningkatan ketepatan keputusan investasi	Mengurangi risiko kerugian, meningkatkan imbal hasil

Manajer Aset	Optimalisasi alokasi portofolio, pemantauan risiko pasar dan kredit secara real-time	Meningkatkan kinerja portofolio, menjaga stabilitas nilai aset
Regulator	Akses pada proyeksi pasar yang andal untuk evaluasi kepatuhan dan transparansi	Memperkuat kepercayaan publik, mendorong stabilitas sistem keuangan

Tabel ini memetakan manfaat strategis yang diperoleh oleh tiga kelompok utama pemangku kepentingan, yaitu investor, manajer aset, dan regulator, dari penerapan model prediksi yang tepat di sektor keuangan. Bagi investor, tabel menunjukkan bahwa manfaat utama terletak pada efisiensi perencanaan modal dan peningkatan ketepatan pengambilan keputusan investasi, yang secara langsung berkontribusi pada pengurangan risiko kerugian dan peningkatan imbal hasil. Manajer aset memperoleh keuntungan dari optimalisasi alokasi portofolio serta pemantauan risiko pasar dan kredit secara real-time, yang mendukung peningkatan kinerja portofolio dan menjaga stabilitas nilai aset dalam jangka panjang. Sementara itu, regulator mendapatkan akses pada proyeksi pasar yang andal, memungkinkan evaluasi kepatuhan dan peningkatan transparansi, sehingga memperkuat kepercayaan publik dan mendorong stabilitas sistem keuangan. Deskripsi ini menegaskan bahwa setiap pihak memperoleh manfaat yang berbeda namun saling melengkapi, sehingga membentuk ekosistem keuangan yang lebih tangguh, adaptif, dan berkelanjutan.

Bab 2. Fondasi Pergerakan Harga Saham

Faktor ekonomi yang mempengaruhi tren harga

Perubahan harga di pasar keuangan dipengaruhi oleh berbagai faktor ekonomi yang saling berhubungan dan membentuk dinamika yang kompleks. Inflasi, tingkat *interest rate*, dan nilai tukar merupakan tiga unsur utama yang menentukan arah pergerakan harga. Kenaikan inflasi dapat mengurangi daya beli serta memengaruhi proyeksi arus kas perusahaan, sehingga berdampak pada penilaian saham. Perubahan *interest rate* memengaruhi biaya modal dan selera investasi, yang pada gilirannya dapat mengubah komposisi portofolio investor. Sementara itu, nilai tukar memengaruhi daya saing ekspor dan kinerja perusahaan multinasional, khususnya di negara yang sangat bergantung pada perdagangan internasional.

Interest rate memiliki jalur transmisi yang berlapis terhadap harga saham. Peningkatan suku bunga menaikkan tingkat diskonto pada arus kas di masa mendatang sehingga menekan valuasi, sekaligus mendorong perpindahan minat investor ke aset berpendapatan tetap. Selain itu, biaya pinjaman yang lebih tinggi dapat menurunkan investasi dan laba perusahaan. Efek ini sering kali diperkuat oleh perubahan persepsi risiko dan kondisi likuiditas di pasar.

Nilai tukar menjadi jembatan antara pasar ekuitas domestik dengan perkembangan global. Fluktuasi kurs dapat memicu aliran modal lintas negara, memengaruhi harga aset, dan menyebarkan guncangan pasar antarwilayah. Perubahan besar pada kurs biasanya diikuti peningkatan volatilitas, terutama di pasar yang lebih rentan terhadap arus modal keluar.

Harga komoditas seperti minyak juga memberi pengaruh besar terhadap tren harga ekuitas. Perubahan harga minyak memengaruhi biaya produksi, inflasi, dan pendapatan negara, dengan dampak yang meluas ke berbagai sektor. Di sisi lain, ketidakpastian kebijakan ekonomi dapat memperkuat keterkaitan antar aset melalui kenaikan volatilitas tersirat dan perubahan ekspektasi pelaku pasar.

Dalam rentang waktu singkat, indikator seperti rasio dividen terhadap harga, *dividend yield*, dan rasio laba terhadap harga digunakan untuk memproyeksikan pergerakan harga harian. Indikator ini membantu mengidentifikasi potensi pembalikan atau kelanjutan tren. Variabel ekonomi yang diringkas melalui *principal component analysis* dapat menggambarkan kondisi makro secara komprehensif, mendukung estimasi volatilitas jangka pendek.

Pengukuran sentimen pasar, misalnya melalui indeks volatilitas, berperan penting dalam menangkap perubahan cepat yang tidak selalu tercermin pada indikator fundamental. Gabungan antara data fundamental, kondisi ekonomi makro, dan sentimen pasar membentuk pandangan yang lebih menyeluruh untuk memprediksi arah pergerakan harga.

Tabel 5. Korelasi Indikator Makro dengan Perubahan IHSG

Indikator Makroekonomi	Korelasi dengan IHSG	Keterangan
Inflasi	Negatif signifikan	Inflasi menekan daya beli dan profitabilitas korporasi
Nilai Tukar Rupiah (USD/IDR)	Negatif signifikan	Pelemahan rupiah berdampak menurun kepercayaan investor.


Suku Bunga BI (BI-7 Days RR)	Potensi negatif tidak signifikan	IHSG relatif tahan terhadap fluktuasi suku bunga jangka pendek
Jumlah Uang Beredar	Positif signifikan	Likuiditas tinggi mendorong kenaikan IHSG
GDP (Pertumbuhan Ekonomi)	Tidak signifikan / variatif	Beberapa studi menunjukkan pengaruh minim atau beragam
Indeks Global (S&P 500, Dow, STI, dsb.)	Beragam positif (STI), negatif (S&P 500 & Dow)	STI positif, sementara S&P 500 & Dow memberikan sinyal negative.
Volatilitas IHSG vs Makro (inflasi, USD/IDR, suku bunga)	Positif signifikan terhadap volatilitas	Ketika makroekonomi fluktuatif, IHSG juga lebih volatil

Tabel ini menggambarkan hubungan antara berbagai indikator makroekonomi dengan pergerakan *Indeks Harga Saham Gabungan* (IHSG), disertai penjelasan mengenai arah dan kekuatan korelasi yang terjadi. Inflasi tercatat memiliki hubungan negatif yang kuat dengan IHSG. Kenaikan inflasi umumnya menurunkan daya beli masyarakat sekaligus menekan tingkat keuntungan perusahaan, sehingga pasar saham cenderung melemah. Hal serupa juga terlihat pada nilai tukar rupiah terhadap dolar Amerika (*USD/IDR*), di mana depresiasi rupiah memengaruhi kepercayaan investor, terutama investor luar negeri, dan dapat memicu arus keluar modal.

Suku bunga acuan *Bank Indonesia* (*BI-7 Days Reverse Repo Rate*) menunjukkan indikasi hubungan negatif, walaupun tidak signifikan. Kondisi ini mengisyaratkan bahwa IHSG relatif tidak terlalu terpengaruh oleh perubahan suku bunga jangka pendek. Sebaliknya, jumlah uang

beredar menunjukkan hubungan positif yang kuat. Tingginya likuiditas di pasar sering kali mendorong minat beli saham dan mengangkat indeks.

Pertumbuhan ekonomi (*Gross Domestic Product* atau *GDP*) memperlihatkan hubungan yang tidak konsisten. Dampaknya terhadap IHSG dapat berbeda-beda, tergantung pada periode, kondisi ekonomi, dan sektor yang mendominasi pertumbuhan. Untuk pengaruh pasar luar negeri, terdapat perbedaan arah korelasi. *Straits Times Index* (STI) Singapura cenderung bergerak searah dengan IHSG, sementara *S&P 500* dan *Dow Jones* di Amerika Serikat justru memberikan sinyal berlawanan. *Volatilitas* IHSG juga meningkat ketika terjadi gejolak pada indikator seperti inflasi, nilai tukar, dan suku bunga. Fluktuasi di ranah makroekonomi ini biasanya diikuti oleh pergerakan harga saham yang lebih tajam, mencerminkan tingginya ketidakpastian di pasar.



Gambar 2. Mekanisme Transmisi Kebijakan Moneter terhadap Perekonomian

Gambar ini menampilkan alur bagaimana kebijakan moneter, melalui *open market operations*, memengaruhi permintaan agregat (*aggregate demand*) dalam perekonomian. Proses dimulai dari operasi pasar terbuka yang memengaruhi cadangan (*reserves*) perbankan. Perubahan cadangan ini berdampak pada suku bunga antarbank semalam (*overnight interbank rate*) serta *monetary base*. Kenaikan atau penurunan cadangan memengaruhi jumlah uang beredar (*money supply*), yang pada gilirannya memengaruhi tingkat suku bunga pasar (*market interest rates*). Suku bunga pasar memengaruhi tingkat suku bunga riil (*real rates*) melalui saluran suku bunga (*interest rate channel*), serta ekspektasi inflasi (*inflation expectations*).

Dari sisi kredit, perubahan suku bunga pasar berdampak pada harga aset (*asset price levels*) yang memengaruhi kekayaan (*wealth channel*) dan nilai jaminan (*collateral*) di jalur kredit luas (*broad credit channel*). Kredit sempit (*narrow credit channel*) juga dipengaruhi langsung melalui pasokan pinjaman (*loan supply*). Nilai tukar (*exchange rate*) juga menjadi saluran penting, di mana perubahan nilai tukar memengaruhi harga relatif aset (*relative asset prices*) dan memengaruhi daya saing ekspor-impor, yang berdampak pada permintaan agregat melalui *exchange rate channel* dan *monetarist channel*.

Keseluruhan alur menunjukkan bahwa kebijakan moneter tidak hanya memengaruhi permintaan agregat secara langsung melalui perubahan suku bunga dan jumlah uang beredar, tetapi juga melalui jalur tidak langsung seperti perubahan harga aset, nilai tukar, serta ekspektasi inflasi. Interaksi saluran-saluran ini membentuk respon keseluruhan perekonomian terhadap kebijakan moneter yang diterapkan.


Faktor psikologis dan perilaku investor

Pergerakan harga saham terbentuk tidak hanya dari dorongan ekonomi dan aspek fundamental, tetapi juga dari dinamika psikologis serta perilaku kolektif para pelaku pasar. Sentimen menjadi salah satu penggerak penting, di mana dominasi *bullish* sering memicu optimisme bersama yang mendorong arus beli kuat, sehingga harga dapat melampaui nilai yang tercermin dari data fundamental. Sebaliknya, ketika sentimen *bearish* menguat, tekanan jual meningkat dan mendorong harga turun. Pengaruh sentimen kerap muncul dengan jeda waktu. Keyakinan atau kekhawatiran yang berkembang dalam benak investor dapat membutuhkan beberapa bulan untuk sepenuhnya terlihat pada pergerakan harga. Pengukuran melalui survei dan indikator berbasis pasar menjadi sarana untuk menangkap tingkat optimisme atau pesimisme kolektif, yang dapat dimanfaatkan sebagai gambaran arah pergerakan harga dalam jangka menengah.

Selain itu, perilaku ikut-ikutan atau *herding* mampu memperbesar gejolak harga. Saat banyak investor mengikuti pola transaksi yang sama—baik karena dorongan emosional maupun kesamaan arus informasi—perubahan harga menjadi lebih tajam dibandingkan yang tercermin dari nilai fundamental. Keadaan ini dapat menciptakan *feedback loop*, di mana kenaikan atau penurunan harga memperkuat keyakinan bersama, sehingga pergerakan semakin ekstrem. Bias kognitif turut membentuk keputusan investasi. *Overconfidence* mendorong pengambilan risiko berlebihan, *loss aversion* membuat enggan merealisasikan kerugian, sedangkan *confirmation bias* menuntun pencarian informasi yang hanya mendukung pandangan awal. Akumulasi bias ini dapat menghasilkan harga yang menyimpang dari nilai wajarnya

dan mendorong praktik perdagangan yang kurang optimal, seperti transaksi berlebihan atau portofolio yang kurang terdiversifikasi.

Dampak bias tersebut sering diperantarai oleh persepsi risiko. Ketika penilaian risiko terdistorsi, pandangan terhadap peluang dan ancaman menjadi tidak seimbang, sehingga memengaruhi rasionalitas keputusan. Hal ini memberi dampak tidak hanya pada kinerja portofolio individu, tetapi juga pada kestabilan pasar secara umum. Keterkaitan antara sentimen, *herding*, dan bias kognitif membentuk sistem perilaku yang saling memengaruhi. Sentimen ekstrem dapat memicu *herding*, sedangkan *herding* dapat memperkuat bias kognitif dengan mempersempit keragaman pandangan di pasar. Gabungan ketiganya memperbesar potensi volatilitas tinggi dan pergeseran harga dari nilai wajar.



Gambar 2. Hubungan Toleransi Risiko Bias Perilaku Investor

Gambar ini menggambarkan hubungan antara tingkat toleransi risiko pada sumbu vertikal dan kepribadian investor pada sumbu

horizontal, disertai pemetaan berbagai jenis *bias* yang memengaruhi pengambilan keputusan di pasar keuangan. Kurva yang terbentuk menunjukkan pergerakan yang meningkat dari titik awal, mencapai puncak, lalu menurun kembali, melambungkan variasi tingkat risiko dari investor konservatif hingga agresif. Pada bagian awal kurva, kelompok yang tergolong konservatif cenderung memiliki toleransi risiko rendah. Karakter ini sering dipengaruhi oleh *loss aversion* atau kecenderungan menghindari kerugian, *mental accounting* yang memisahkan alokasi dana berdasarkan pertimbangan emosional, serta *anchoring* yang membuat keputusan terikat pada informasi awal.

Seiring pergeseran menuju tengah kurva, muncul kategori investor moderat. Toleransi risiko pada tahap ini meningkat, diiringi kecenderungan terhadap *regret aversion* atau menghindari rasa penyesalan, *representativeness* yang menilai situasi berdasarkan kemiripan dengan pengalaman sebelumnya, dan *overconfidence* yang memicu keyakinan berlebihan terhadap kemampuan sendiri. Puncak kurva memperlihatkan *growth investors* yang memiliki toleransi risiko tertinggi. Kelompok ini sering terpengaruh oleh *gambler's fallacy* kepercayaan pada pola peluang yang keliru dan *availability bias* yang membuat informasi mudah diingat dianggap lebih relevan dari kenyataannya. Pada fase menurun, terlihat kelompok agresif yang masih berani mengambil risiko, namun mulai terbatas oleh faktor seperti *self-control*. Keseimbangan antara keberanian mengambil peluang dan kemampuan menahan dorongan emosional menjadi penentu keberlangsungan strategi mereka.

Hubungan antara indikator teknikal dan dinamika harga


Indikator teknikal berfungsi sebagai instrumen yang merangkum pola pergerakan harga serta momentum pasar, sehingga membantu pelaku pasar mengenali fase-fase pergerakan secara lebih tepat. Berdasarkan data historis harga dan volume, indikator ini memberikan gambaran mengenai tren, tingkat volatilitas, dan potensi pembalikan arah harga. Beberapa indikator yang secara konsisten menunjukkan nilai prediktif meliputi *moving averages* baik sederhana maupun eksponensial, *Moving Average Convergence Divergence (MACD)*, *Bollinger Bands*, dan *Relative Strength Index (RSI)*. Kombinasi beberapa indikator dapat meningkatkan keandalan sinyal transaksi, terutama bila dioptimalkan menggunakan pendekatan berbasis *machine learning*. Uji pada berbagai kelas aset, mulai dari saham hingga valuta asing, memperlihatkan bahwa indikator-indikator ini mampu menangkap dinamika pasar yang berulang, merepresentasikan perubahan momentum, dan membantu mengantisipasi pergerakan harga.

Di antara indikator tersebut, *moving averages* memiliki posisi penting dalam mengilustrasikan keberlanjutan tren. Dengan kemampuannya menyaring fluktuasi jangka pendek, indikator ini memudahkan identifikasi arah tren yang mendasar. *Moving averages* jangka panjang, seperti yang berbasis 200 hari, sering digunakan untuk mengisyaratkan tren yang bertahan, sedangkan jangka pendek membantu mengenali permulaan atau pelemahan tren. Pola *crossover* antara dua *moving averages* sering dimanfaatkan sebagai penanda aksi jual atau beli. Selain itu, garis ini juga berperan sebagai dukungan dan resistensi dinamis. *RSI* menjadi alat penting untuk mendeteksi kondisi *overbought* atau *oversold* yang sering mendahului pembalikan harga. Batas umum yang digunakan adalah di atas 70 untuk *overbought* dan di bawah 30 untuk *oversold*. Penyesuaian batas, misalnya di atas 80 dan di bawah 20, dapat meningkatkan akurasi sinyal

pada kondisi pasar tertentu, sehingga kalibrasi sesuai karakteristik instrumen menjadi hal yang penting.

MACD memadukan fungsi *moving averages* dengan indikator momentum untuk mengenali perubahan tren lebih awal. Persilangan garis *MACD* dengan garis sinyalnya sering kali menjadi tanda awal pergeseran arah harga. Sementara itu, *Bollinger Bands* memanfaatkan deviasi standar untuk mengukur volatilitas serta mengenali titik jenuh harga. Pelebaran pita mengindikasikan volatilitas yang meningkat, sedangkan penyempitan pita menunjukkan potensi pergerakan signifikan. Penggunaan indikator secara terpadu bertujuan tidak hanya untuk mengonfirmasi sinyal, tetapi juga meminimalkan risiko *false signal*. Pendekatan multi-indikator memberi peluang untuk melihat kesesuaian bukti sebelum membuat keputusan. Dalam praktik, pelaku pasar kerap memadukan *moving averages* untuk tren, *RSI* untuk pembalikan, *MACD* untuk momentum, dan *Bollinger Bands* untuk menilai volatilitas.

Keberhasilan pemanfaatan indikator teknikal sangat dipengaruhi oleh pemahaman atas karakter masing-masing indikator dan penyesuaian parameter terhadap kondisi pasar. Integrasi indikator ke dalam sistem berbasis teknologi menjadikannya komponen yang mendukung pengambilan keputusan secara adaptif terhadap dinamika pasar.



Gambar 3. Contoh Pola *Moving Average (MA)* dan *MACD* pada Grafik Harga

Gambar ini memperlihatkan pergerakan harga harian yang diperkaya dengan dua indikator teknikal utama, yaitu *Exponential Moving Average (EMA)* dan *Moving Average Convergence/Divergence (MACD)*. Pada bagian atas grafik, dua garis *EMA* ditampilkan untuk periode 12 hari (garis hijau) dan 26 hari (garis merah). Garis *EMA* 12 hari memiliki respons yang lebih cepat terhadap perubahan harga, sedangkan *EMA* 26 hari bergerak lebih halus. Persilangan kedua garis ini sering dimanfaatkan untuk membaca arah tren. Ketika *EMA* 12 hari memotong *EMA* 26 hari dari bawah ke atas, hal tersebut biasanya diartikan sebagai sinyal *bullish*, menandakan potensi penguatan tren. Sebaliknya, persilangan dari atas ke bawah sering dikaitkan dengan sinyal *bearish* atau potensi pelemahan.

Bagian bawah grafik menampilkan indikator *MACD* yang terdiri dari tiga komponen utama. *MACD Line* (garis biru) merepresentasikan selisih antara *EMA* 12 hari dan *EMA* 26 hari. *Signal Line* (garis merah muda) merupakan *EMA* 9 hari dari *MACD Line*, yang berfungsi memberikan sinyal beli atau jual. Sementara itu, *MACD Histogram* (batang hijau atau merah)

menunjukkan selisih antara *MACD Line* dan *Signal Line*, sehingga membantu mengukur kekuatan momentum pergerakan harga. Persilangan *MACD Line* dan *Signal Line* menjadi salah satu perhatian utama. Ketika *MACD Line* bergerak melewati *Signal Line* dari bawah ke atas, hal ini menunjukkan penguatan momentum naik. Sebaliknya, pergerakan dari atas ke bawah sering mengisyaratkan momentum menurun. Panjang histogram mencerminkan besarnya kekuatan tren, sementara penyusutan histogram menunjukkan melemahnya dorongan harga. Kombinasi *EMA* dan *MACD* memberi gambaran yang lebih menyeluruh untuk memahami arah tren, kekuatan momentum, serta potensi titik masuk atau keluar pasar dengan pertimbangan yang lebih matang.

Pola siklus pasar dan volatilitas


Pasar keuangan bergerak melalui rangkaian fase berulang yang biasanya digambarkan sebagai periode kenaikan, penurunan, dan jeda. Setiap fase mencerminkan dinamika yang dipengaruhi oleh perubahan persepsi risiko, kondisi pendanaan, serta faktor fundamental makroekonomi. Dalam kerangka *financial cycle*, harga aset cenderung menguat diiringi optimisme berlebih, kemudian mengalami koreksi tajam ketika ekspektasi risiko meningkat. Fenomena ini sejalan dengan konsep *boom-bust cycle*, di mana kenaikan harga yang berkesinambungan meningkatkan eksposur risiko hingga akhirnya memicu penyesuaian signifikan. Penyatuan tipologi siklus bisnis dan siklus keuangan memberikan gambaran yang lebih menyeluruh terhadap pergerakan

harga ekuitas. Pergeseran fase pasar tidak hanya dipengaruhi faktor ekonomi riil, seperti pertumbuhan produk domestik bruto atau inflasi, tetapi juga oleh mekanisme keuangan yang bersifat *self-reinforcing*, misalnya keterkaitan antara ekspektasi risiko dan ketersediaan pembiayaan. Pada fase ekspansi, likuiditas yang melimpah dan optimisme mendorong harga bergerak naik, sementara fase kontraksi diwarnai pengetatan pembiayaan dan meningkatnya ketidakpastian yang menekan harga.

Volatilitas berfungsi sebagai penanda intensitas perubahan antar fase tersebut. Indeks seperti *CBOE Volatility Index* (VIX) memberikan gambaran langsung atas ekspektasi pasar terhadap volatilitas masa depan. Dihitung dari harga opsi, indeks ini merefleksikan pandangan kolektif pelaku pasar mengenai risiko jangka pendek. Lonjakan VIX sering mendahului atau bertepatan dengan memburuknya kondisi pasar, sehingga dapat dimanfaatkan sebagai sinyal awal untuk mengantisipasi potensi penurunan atau periode risiko tinggi. Perubahan volatilitas tidak hanya mencerminkan keadaan saat ini, tetapi juga berperan sebagai proyeksi dinamika harga ke depan. Lonjakan tajam volatilitas kerap diikuti penyesuaian harga yang besar, baik berupa koreksi maupun pembalikan tren. Sebaliknya, periode volatilitas rendah mengindikasikan kestabilan relatif, meski kadang menjadi tanda akumulasi tekanan yang dapat memicu perubahan signifikan.

Selain faktor struktural, pola musiman turut membentuk perilaku harga. Efek kalender seperti *January effect*, *turn-of-the-month effect*, dan pola seputar hari libur merupakan contoh anomali musiman yang sering teramati. Perbedaan rata-rata imbal hasil, volume perdagangan, dan volatilitas pada periode tertentu sering terkait dengan faktor seperti *tax-*

loss selling, penyeimbangan portofolio di akhir periode, atau aliran dana institusional yang bertepatan dengan momen kalender. Interaksi antara siklus pasar, volatilitas, dan faktor musiman membentuk kerangka pemahaman yang lebih utuh terhadap perilaku harga aset. Identifikasi fase pasar dan pemantauan indikator volatilitas memberi landasan bagi pengambilan langkah strategis yang dapat memaksimalkan peluang sekaligus mengurangi risiko. Pendekatan ini menjadi lebih relevan saat diintegrasikan dengan strategi pengelolaan risiko yang adaptif terhadap perubahan dinamika pasar.



Gambar 4. *Uptrend, Sideways, dan Downtrend*

Gambar ini memperlihatkan dinamika pergerakan harga dalam tiga tahap utama yang saling berkesinambungan. Tahap awal adalah *uptrend*, ditandai dengan formasi *higher highs* dan *higher lows*. Setiap puncak dan lembah yang terbentuk berada pada posisi lebih tinggi dibandingkan titik sebelumnya, mencerminkan dorongan beli yang kuat. Kondisi ini sering diasosiasikan dengan meningkatnya optimisme pelaku pasar dan kecenderungan harga untuk terus bergerak naik. Pergerakan kemudian

memasuki tahap *sideways* yang sering disebut sebagai fase konsolidasi. Pada fase ini, harga bergerak dalam kisaran atau *trading range* yang relatif stabil, di mana puncak dan lembah tidak menunjukkan kenaikan atau penurunan signifikan. Situasi ini menggambarkan keseimbangan antara tekanan beli dan jual, sehingga pasar bergerak datar sambil menunggu pemicu yang dapat mengarahkan tren selanjutnya. Fase *sideways* menjadi momen penting bagi sebagian pelaku pasar untuk mengantisipasi terjadinya *breakout* atau *breakdown*.

Tahap berikutnya adalah *downtrend*, yang dikenali melalui terbentuknya *lower highs* dan *lower lows*. Setiap puncak dan lembah berada pada posisi lebih rendah daripada sebelumnya, menandakan dominasi penjual dalam mengendalikan harga. Pergerakan ini kerap diiringi melemahnya minat beli dan meningkatnya kewaspadaan investor. Ketiga fase ini membentuk pola siklus yang sering muncul di berbagai instrumen keuangan. Pemahaman terhadap urutan dan ciri setiap tahap membantu pelaku pasar merumuskan langkah yang lebih terukur dalam mengambil posisi maupun mengelola risiko.

Interaksi kompleks antar faktor penentu harga

Pasar keuangan bergerak dalam pola berulang yang terdiri atas fase kenaikan, penurunan, dan jeda. Fase kenaikan biasanya ditandai dengan suasana optimistis, peningkatan arus likuiditas, serta kenaikan harga aset yang berkesinambungan. Sebaliknya, fase penurunan terjadi saat ekspektasi risiko meningkat, akses pembiayaan menyempit, dan faktor eksternal seperti gejolak ekonomi atau politik memicu koreksi harga. Sementara itu, fase jeda atau konsolidasi mencerminkan kondisi

relatif stabil, di mana pelaku pasar menanti pemicu baru sebelum mengambil langkah berikutnya. Dalam kerangka *financial cycle*, pergerakan harga aset mencerminkan interaksi timbal balik antara persepsi risiko, ketersediaan pembiayaan, dan perkembangan makroekonomi. Kondisi pembiayaan yang longgar dan dominasi sentimen positif mendorong tren penguatan harga, namun optimisme yang berlebihan dapat memicu *boom-bust cycle*—fase lonjakan harga cepat yang diikuti penurunan tajam ketika ekspektasi berubah. Integrasi pemahaman siklus bisnis dan keuangan membantu menjelaskan dinamika ini, karena faktor riil dan keuangan saling memengaruhi.

Volatilitas berfungsi sebagai indikator intensitas perubahan di antara fase-fase tersebut. Indeks seperti *CBOE Volatility Index (VIX)*, yang dihitung dari harga opsi, mencerminkan ekspektasi pasar terhadap fluktuasi jangka pendek. Lonjakan nilai *VIX* sering menjadi sinyal meningkatnya ketidakpastian, sedangkan volatilitas rendah dapat memberi kesan stabilitas meski kadang menjadi tanda akumulasi ketegangan yang berpotensi memicu perubahan signifikan. Keterkaitan antara variabel makroekonomi dan sentimen pasar memperkuat dinamika siklus. Pertumbuhan produk domestik bruto, kebijakan moneter, dan kondisi kredit memengaruhi persepsi pasar, sementara sentimen dapat memperbesar atau meredam respons terhadap perubahan tersebut. Guncangan negatif, misalnya, dapat memicu pesimisme luas yang memperdalam perlambatan ekonomi melalui penurunan konsumsi dan investasi. Fenomena ini membentuk *feedback loop*, di mana sentimen tidak hanya mencerminkan kondisi makro, tetapi juga ikut membentuk arah pasar.

Pendekatan ekonometrik seperti *vector autoregression* (*VAR*) dan *structural VAR* (*SVAR*) digunakan untuk menangkap interaksi dua arah ini. Model dengan mekanisme *regime-switching* memungkinkan hubungan antarvariabel menyesuaikan diri sesuai kondisi ekonomi dan suasana hati pasar. Pemahaman ini bermanfaat untuk melihat bagaimana kejutan makro atau sentimen mengubah struktur korelasi antar faktor keuangan dan memengaruhi jalur transmisi risiko. Kejutan pasar, baik yang bersumber dari aspek makro maupun sentimen, kerap meningkatkan keterkaitan antar kelas aset. Pada periode ketidakpastian tinggi, korelasi lintas pasar meningkat sehingga mengurangi efektivitas diversifikasi. Hal ini terlihat saat guncangan global mengubah sentimen secara signifikan, memicu pergerakan serentak di berbagai instrumen keuangan.

Selain faktor struktural, pengaruh musiman juga terlihat dalam pergerakan harga. *January effect*, *turn-of-the-month effect*, dan pola perdagangan yang berkaitan dengan hari libur menunjukkan bahwa waktu dalam kalender dapat memicu variasi dalam imbal hasil, volume, dan volatilitas. Pemicu utamanya meliputi *tax-loss selling*, penyeimbangan portofolio di akhir periode, serta arus dana institusional yang berpola kalender. Dengan memahami keterpaduan siklus pasar, indikator volatilitas, interaksi makro-sentimen, dan efek musiman, pelaku pasar dapat menyusun strategi adaptif. Identifikasi fase yang tepat, pemantauan volatilitas, dan pengenalan pola musiman menjadi fondasi penting dalam pengelolaan risiko sekaligus pemanfaatan peluang. Perspektif yang menggabungkan aspek makroekonomi, perilaku pasar, dan indikator teknis menghasilkan strategi yang lebih tangguh dalam

menghadapi guncangan dan memanfaatkan dinamika pasar yang terus berkembang.

Bab 3. Perbandingan Pendekatan Klasik dan Berbasis AI

Asumsi linear dalam pendekatan Klasik

Pendekatan klasik dalam pemodelan pasar modal bertumpu pada pandangan bahwa hubungan antarvariabel bersifat aditif, stabil, dan tidak berubah seiring waktu. Dalam kerangka ini, setiap faktor penjelas diperlakukan memiliki pengaruh yang proporsional dan konsisten terhadap variabel sasaran. Asumsi tersebut juga mencakup keseragaman varians atau *homoscedasticity* serta harapan bahwa kesalahan mengikuti distribusi normal. Kekuatan pendekatan ini terletak pada kemudahan estimasi dan kemampuannya menyajikan interpretasi yang jelas, namun kesederhanaannya sering kali membatasi keluwesan saat menghadapi dinamika data yang kompleks. Perkembangan pasar saham modern memperlihatkan bahwa sifat data kerap menantang validitas asumsi tersebut. Harga saham menampilkan volatilitas tinggi, ketidakstasioneran, dan pergeseran rezim yang terjadi tiba-tiba. Gejala seperti *volatility clustering*, *heteroscedasticity*, dan distribusi dengan ekor tebal (*fat-tail behavior*) menunjukkan bahwa asumsi koefisien konstan sulit terpenuhi. Dalam kondisi demikian, model linear tradisional kerap gagal memprediksi lonjakan atau penurunan harga mendadak, sehingga menurunkan kinerja proyeksi di luar sampel.

Selain itu, perilaku pelaku pasar dan ketidaksempurnaan mekanisme perdagangan menimbulkan hubungan non-linear yang berubah seiring waktu. Dampak kejutan makroekonomi tidak selalu bersifat proporsional; respons harga dapat dipengaruhi oleh likuiditas


pasar atau tingkat sentimen yang sedang berlaku. Interaksi antar faktor pasar kerap bersifat sinergis dan multiplikatif, memunculkan efek ambang (*threshold effects*) atau kejenuhan (*saturation effects*) yang tidak dapat diakomodasi oleh model linear. Sebagai ilustrasi, perubahan kebijakan moneter dapat memicu respons harga yang sangat berbeda ketika pasar sedang diliputi optimisme dibandingkan saat sentimen sedang pesimis. Hal ini menimbulkan efek non-monotonik yang mengaburkan garis hubungan linear, sementara *feedback loop* yang terbentuk di pasar terabaikan. Ketidaksesuaian antara asumsi model dan kerumitan alami data membawa risiko yang nyata, termasuk kecenderungan meremehkan potensi risiko atau melakukan salah harga (*mispricing*) terhadap aset.

Keterbatasan tersebut mendorong berkembangnya pemodelan berbasis *artificial intelligence* (AI) yang tidak mengikatkan diri pada asumsi linear atau distribusi tertentu. Model seperti *long short-term memory* (LSTM), *transformer-based models*, dan *ensemble learning* mampu memotret pola non-linear, menangkap ketergantungan jangka panjang, serta memodelkan interaksi kompleks antarvariabel. Fleksibilitas ini membuatnya mampu beradaptasi terhadap perubahan struktur data, baik yang berlangsung secara bertahap maupun mendadak. Pendekatan ini juga memungkinkan integrasi berbagai sumber informasi, mulai dari indikator ekonomi makro hingga sentimen pasar yang diperoleh melalui *news analytics* atau platform media sosial. Hal tersebut penting karena pasar dipengaruhi tidak hanya oleh data fundamental, tetapi juga oleh persepsi dan emosi kolektif. Kombinasi data kuantitatif dan kualitatif menghasilkan potret yang lebih utuh mengenai pergerakan harga.

Meski demikian, penerapan AI membawa tantangan tersendiri. Kompleksitas algoritme dapat mengurangi transparansi dan kemudahan

interpretasi, sementara kebutuhan akan data dalam jumlah besar menimbulkan risiko *overfitting*. Pengelolaan yang cermat diperlukan untuk menjaga keseimbangan antara kecanggihan teknis dan keandalan hasil. Dibandingkan dengan kekakuan asumsi linear, AI menawarkan keluwesan yang lebih besar dalam memahami dinamika pasar. Peralihan dari pendekatan klasik ke model berbasis AI mencerminkan kebutuhan untuk menyesuaikan alat pengambilan keputusan dengan karakter pasar yang kian kompleks. Model linear tetap memiliki tempat karena kesederhanaan dan efisiensinya, tetapi AI membuka peluang untuk strategi pengelolaan risiko dan keputusan investasi yang lebih responsif, presisi, dan selaras dengan realitas perilaku pasar.

Non-Linear Patterns



Gambar 5. Contoh Pola Nonlinear pada Pergerakan Harga

Gambar ini memperlihatkan dua contoh visual pola *nonlinear* yang sering dijumpai dalam pergerakan harga atau data deret waktu. Pada panel sebelah kiri, titik-titik data membentuk pola melengkung ke atas yang menunjukkan adanya percepatan pertumbuhan. Garis kurva yang mengikuti titik-titik tersebut memperlihatkan bahwa laju kenaikan harga

tidak konstan, melainkan semakin cepat seiring bertambahnya waktu atau faktor pemicunya. Fenomena ini bisa muncul dalam pasar saat optimisme investor meningkat pesat atau ketika ada dorongan fundamental yang kuat, seperti rilis berita positif atau inovasi produk. Panel sebelah kanan menampilkan pola *nonlinear* berbentuk kurva-S (*sigmoid*). Pada awalnya, pergerakan harga relatif lambat dengan fluktuasi kecil. Selanjutnya, terjadi fase percepatan tajam di tengah kurva, sebelum akhirnya mencapai titik jenuh dan bergerak mendatar di kisaran nilai maksimum baru. Pola seperti ini sering diasosiasikan dengan proses adopsi teknologi, pertumbuhan pasar yang mulai matang, atau kondisi ketika harga mencapai level resistensi psikologis yang kuat. Kedua ilustrasi ini menegaskan bahwa pergerakan harga tidak selalu mengikuti garis lurus atau tren linier sederhana. Dalam kenyataannya, harga dapat bereaksi terhadap berbagai faktor eksternal dan internal secara tidak proporsional. Memahami pola *nonlinear* membantu pelaku pasar mengenali fase akselerasi, titik balik, dan potensi kejenuhan tren. Hal ini bermanfaat untuk mengatur strategi masuk dan keluar pasar dengan mempertimbangkan dinamika yang tidak dapat dijelaskan sepenuhnya oleh model linier biasa.

Keterbatasan menghadapi data yang tidak stasioner

Pasar keuangan modern ditandai oleh sifat dinamis yang kompleks, di mana data yang dihasilkan cenderung tidak stasioner. Ketidakstasioneran, dalam kerangka deret waktu, mengacu pada perubahan sifat statistik seperti rata-rata dan varians sepanjang periode observasi. Perubahan ini mengimplikasikan bahwa hubungan antara

variabel yang diamati tidak konstan dan dapat bergeser akibat tren, musim, atau peristiwa mendadak yang mengubah struktur pasar. Fenomena ini sering kali disebabkan oleh faktor eksternal seperti guncangan ekonomi, perubahan kebijakan moneter, krisis geopolitik, maupun fluktuasi perilaku pelaku pasar.

Pada kondisi tidak stasioner, model dengan parameter tetap—yang umum digunakan dalam pendekatan klasik—menghadapi keterbatasan signifikan. Model ini dibangun dengan asumsi bahwa parameter yang diestimasi dari data historis akan tetap relevan di masa depan. Asumsi ini jarang terpenuhi dalam pasar yang bergerak cepat, di mana dinamika dapat berubah secara tiba-tiba, menyebabkan parameter yang sebelumnya akurat menjadi usang. Misalnya, hubungan antara suku bunga dan harga saham yang stabil dalam periode tertentu dapat berubah drastis ketika terjadi intervensi kebijakan moneter atau guncangan ekonomi global.

Keterlambatan model parameter tetap dalam beradaptasi dengan pergeseran rezim pasar mengakibatkan kinerja prediksi yang menurun. Saat kondisi pasar bergeser dari periode volatilitas rendah ke volatilitas tinggi, model tersebut tidak mampu menyesuaikan estimasi risikonya secara tepat waktu. Akibatnya, kesalahan prediksi meningkat dan keputusan berbasis model menjadi kurang andal. Hal ini berimplikasi serius pada strategi manajemen risiko, alokasi aset, dan perencanaan investasi yang bergantung pada proyeksi pasar yang akurat.

Berbeda dengan model klasik, pendekatan berbasis *artificial intelligence* (AI) dirancang dengan fleksibilitas yang lebih tinggi dalam menghadapi ketidakstasioneran. Model adaptif yang diimplementasikan melalui algoritma pembelajaran mesin dapat memperbarui parameter

secara dinamis seiring masuknya data baru. Kemampuan ini memungkinkan AI untuk mendeteksi perubahan rezim pasar lebih cepat, mengidentifikasi pola baru, dan menyesuaikan proyeksi dengan kondisi terkini. Sebagai contoh, **recurrent neural networks** (RNN) dan **long short-term memory** (LSTM) mampu memanfaatkan informasi historis sekaligus menangkap dinamika jangka panjang maupun jangka pendek.

Selain itu, teknik **ensemble** seperti **gradient boosting** dan **random forests** memberikan ketahanan terhadap perubahan struktural karena menggabungkan prediksi dari berbagai model yang dilatih pada subset data yang berbeda. Pendekatan ini mengurangi risiko ketergantungan pada satu set parameter tetap yang mungkin tidak lagi relevan saat terjadi perubahan mendadak di pasar. Dengan kemampuan menyesuaikan bobot prediksi berdasarkan kinerja terkini, model adaptif ini dapat mempertahankan akurasi meski sifat distribusi data berubah.

Fenomena seperti **volatility clustering**, ekor gemuk (**fat tails**), dan **regime switching** menuntut penggunaan kerangka prediksi yang mampu mengakomodasi hubungan nonlinier dan variabel yang saling bergantung secara dinamis. Dalam hal ini, AI memberikan keunggulan karena dapat memodelkan interaksi kompleks antara faktor-faktor pasar, termasuk keterkaitan antara indikator makroekonomi, sentimen investor, dan likuiditas. Model berbasis pembelajaran mendalam, misalnya, dapat mengenali bahwa respons pasar terhadap guncangan ekonomi tidak selalu sebanding dengan besarnya, melainkan dipengaruhi oleh kondisi awal pasar dan persepsi pelaku ekonomi.

Kelebihan lain dari pendekatan adaptif adalah kemampuannya mengintegrasikan sumber data heterogen secara real time, seperti data transaksi, berita keuangan, dan sinyal media sosial. Dengan demikian,


model dapat menangkap perubahan sentimen dan pergeseran struktural bahkan sebelum tercermin sepenuhnya dalam harga aset. Hal ini sangat berharga dalam lingkungan yang rawan kejutan (*shock-prone*), di mana kecepatan respons menjadi faktor pembeda utama antara keberhasilan dan kegagalan strategi investasi.

Namun demikian, penerapan model adaptif bukan tanpa tantangan. Kompleksitas algoritma dapat menimbulkan risiko *overfitting*, terutama jika model terlalu sensitif terhadap fluktuasi jangka pendek yang tidak mencerminkan perubahan fundamental. Oleh karena itu, diperlukan mekanisme validasi yang ketat serta strategi regulasi parameter agar model tetap seimbang antara responsif terhadap perubahan dan stabil terhadap noise pasar. Dalam konteks ini, teknik seperti *regularization* dan *dropout* pada jaringan saraf dapat membantu menjaga generalisasi model.

Di sisi lain, penting untuk memahami bahwa tidak semua perubahan pasar memerlukan penyesuaian model secara drastis. Terdapat kondisi di mana fluktuasi sementara tidak mempengaruhi tren jangka panjang secara signifikan. Oleh sebab itu, model adaptif yang efektif perlu dilengkapi dengan mekanisme deteksi rezim yang mampu membedakan antara sinyal perubahan struktural dan noise acak. Pendekatan ini memastikan bahwa sumber daya komputasi difokuskan pada adaptasi terhadap perubahan yang benar-benar signifikan bagi pengambilan keputusan.

Dengan mempertimbangkan dinamika pasar yang semakin kompleks dan cepat berubah, ketidakstasioneran menjadi faktor utama yang membedakan efektivitas antara pendekatan klasik dengan parameter tetap dan pendekatan berbasis AI yang adaptif. Keterbatasan

model klasik dalam mengikuti perubahan rezim menjadikan AI sebagai pilihan yang lebih unggul dalam banyak skenario, khususnya ketika tujuan utamanya adalah mempertahankan akurasi prediksi dan relevansi informasi di tengah lanskap pasar yang terus berevolusi.



Gambar 5. Pergeseran Rezim Varians pada *Return* Saham

Gambar ini menampilkan ilustrasi probabilitas terperhalus (*smoothed probability*) untuk tiga kategori rezim varians pada *return* saham: rendah, sedang, dan tinggi. Setiap panel menunjukkan perubahan peluang suatu periode berada dalam rezim tertentu sepanjang kurun waktu 2000 hingga 2020. Panel pertama merepresentasikan rezim varians rendah, ditandai dengan nilai probabilitas mendekati 1,0 yang menunjukkan kondisi pasar stabil dengan fluktuasi minimal. Meskipun mendominasi pada awal periode, rezim ini kerap diselingi lonjakan singkat yang mengindikasikan peralihan ke kondisi varians lebih tinggi.

Panel kedua menggambarkan rezim varians sedang. Periode ini mulai sering muncul pada pertengahan hingga akhir dekade 2000-an, dan cenderung bertahan sejak 2012 hingga akhir pengamatan. Probabilitas yang konsisten tinggi mencerminkan pasar berada dalam kondisi volatilitas moderat, lebih dinamis dibanding rezim rendah namun belum mencapai tingkat ketidakpastian ekstrem. Panel ketiga menunjukkan rezim varians tinggi, yang jarang terjadi tetapi jelas terlihat pada masa krisis keuangan global 2008–2009. Pada periode ini, probabilitas mendekati 1,0, menandakan ketidakpastian yang sangat besar disertai pergerakan harga harian yang jauh di atas normal.

Ilustrasi ini memberikan gambaran bahwa pasar tidak berada dalam satu kondisi tetap, melainkan mengalami pergeseran antar rezim seiring perubahan faktor ekonomi, dinamika sentimen investor, dan pengaruh eksternal. Memahami transisi tersebut memungkinkan perencanaan strategi yang lebih responsif dalam menghadapi variasi tingkat risiko dan pola pergerakan harga.

Kerentanan terhadap sinyal palsu dan Anomali

Dalam dinamika pasar keuangan, salah satu tantangan yang paling sering dihadapi adalah keberadaan sinyal palsu yang muncul akibat interaksi kompleks antara noise, anomali struktural, dan perilaku pelaku pasar. Fenomena ini dapat menutupi isyarat sejati yang merefleksikan kondisi fundamental, sehingga menyulitkan proses identifikasi pola yang relevan. Pergerakan harga yang seharusnya mencerminkan keseimbangan antara permintaan dan penawaran sering kali terdistorsi oleh faktor non-fundamental, seperti praktik perdagangan berfrekuensi

tinggi, kebijakan regulasi tertentu, atau reaksi berlebihan terhadap informasi sesaat.

Noise pasar dapat bersumber dari berbagai elemen. Salah satunya adalah efek *market microstructure*, di mana mekanisme perdagangan, kebijakan harga batas, atau sistem penyelesaian transaksi seperti *T+1 settlement* menciptakan pergeseran harga sementara yang tidak berhubungan dengan nilai intrinsik aset. Intervensi semacam ini, ketika dikombinasikan dengan aktivitas algoritmik berkecepatan tinggi, dapat menghasilkan sinyal jangka pendek yang menyesatkan. Selain itu, bias perilaku investor, seperti keterbatasan perhatian atau kecenderungan bereaksi berlebihan terhadap berita, memperbesar potensi kemunculan anomali dalam data harga. Bahkan, dalam sistem sosial-ekonomi yang memiliki *long-range memory*, derau dapat bertahan lama dan membentuk autokorelasi yang menyerupai tren pasar, padahal sejatinya hanyalah fluktuasi acak yang berulang.

Apabila anomali dan derau ini tidak dikenali atau diolah dengan benar, dampaknya dapat mengarah pada terbentuknya korelasi semu dan bias dalam estimasi parameter model. Kondisi ini membuat variabel-variabel yang sebenarnya tidak signifikan tampak seolah memiliki pengaruh penting terhadap harga. Akibatnya, model prediktif yang dibangun di atas fondasi yang salah akan mengalami penurunan kinerja ketika diaplikasikan pada data baru. Selain itu, interpretasi hasil menjadi rentan terhadap kesalahan, sehingga dapat memengaruhi keputusan strategis yang diambil oleh pelaku pasar maupun pembuat kebijakan.

Upaya meminimalkan efek derau dan anomali memerlukan teknik penyaringan yang efektif. Pendekatan klasik memanfaatkan *state-space model* dan *Kalman filter* untuk memisahkan komponen sinyal dari data

yang terkontaminasi derau berdasarkan sifat statistik sistem. Teknik ini membantu mempertahankan struktur inti pergerakan harga sambil mengurangi fluktuasi yang bersifat sementara. Selain itu, strategi *time series smoothing* mampu meningkatkan akurasi perkiraan dengan meredam gejolak jangka pendek, sehingga pola mendasar dapat terlihat lebih jelas.

Kemajuan teknologi komputasi menghadirkan alternatif yang lebih adaptif melalui pemanfaatan kecerdasan buatan. Algoritme *machine learning*, seperti *clustering-based decomposition*, digunakan untuk mendeteksi anomali secara otomatis. Model *deep learning* yang memanfaatkan *autoencoder* dan *generative adversarial networks (GANs)* mampu mempelajari hubungan non-linear yang kompleks dalam data, sehingga dapat menyaring sinyal palsu dengan lebih presisi. Keunggulan pendekatan ini terletak pada kemampuannya beradaptasi terhadap perubahan struktural pasar yang cepat, di mana hubungan antarvariabel dapat bergeser dalam hitungan jam bahkan menit.

Dalam praktiknya, penyaringan sinyal tidak hanya bertujuan meningkatkan akurasi prediksi, tetapi juga untuk menjaga stabilitas sistem pengambilan keputusan. Derau yang tidak terkendali dapat memicu reaksi berantai, seperti peningkatan volatilitas, penurunan likuiditas, dan penyebaran ketidakpastian lintas pasar. Oleh karena itu, pendekatan berbasis AI menjadi relevan karena mampu mengintegrasikan berbagai sumber data, baik dari harga historis, indikator teknikal, maupun sentimen pasar, untuk mengidentifikasi sinyal yang benar-benar mencerminkan pergerakan fundamental.

Dengan demikian, tantangan terbesar bukanlah menghilangkan derau sepenuhnya—karena dalam sistem pasar yang kompleks, hal itu

nyaris mustahil melainkan merancang mekanisme adaptif yang dapat membedakan antara sinyal sejati dan sinyal palsu. Integrasi teknik penyaringan klasik dengan kapabilitas *machine learning* yang dinamis menawarkan peluang untuk membangun sistem prediksi yang lebih andal, responsif, dan sesuai dengan realitas pasar modern yang penuh ketidakpastian.



Gambar 6. Contoh Sinyal Palsu (*False Breakout*) pada Pasar dengan Tren Turun

Gambar ini menampilkan pergerakan harga harian pasangan mata uang *GBP/JPY* selama fase tren turun (*downtrend*), dengan sorotan pada kemunculan beberapa sinyal palsu (*false breakouts*). Tiga momen utama ditandai, terdiri atas dua *small false-break* dan satu *large false-break*. Pada *small false-break* pertama, harga sempat menembus area *resistance*

tipis, namun tidak mampu bertahan di atasnya. Penembusan singkat ini segera diikuti kembalinya harga ke bawah level tersebut, mengisyaratkan lemahnya dorongan beli untuk memperkuat *breakout*. *Large false-break* yang terjadi di bagian tengah grafik menunjukkan lonjakan harga yang lebih tajam dan menembus *resistance* cukup jauh. Meskipun tampak meyakinkan pada awalnya, momentum tersebut cepat memudar. Harga berbalik turun dengan tajam hingga menembus kembali level awal. Lonjakan seperti ini kerap menjadi pemicu minat beli yang kemudian berujung kerugian ketika pembalikan arah terjadi secara tiba-tiba. *Small false-break* kedua mengulang pola yang sama, di mana harga mencoba melampaui *resistance* dalam tren menurun, tetapi kembali gagal mempertahankan kenaikan. Setelah kegagalan ini, penurunan harga justru berlangsung lebih curam, melanjutkan dominasi tren turun.

Ilustrasi ini menegaskan bahwa pada pasar dengan tren menurun, sinyal palsu kerap muncul sebagai jebakan bagi pelaku pasar. Pengamatan yang cermat terhadap pola *false breakout* memberikan keuntungan strategis, karena mendorong pelaku pasar untuk menunggu konfirmasi yang lebih kuat, baik melalui indikator teknikal maupun perilaku volume, sebelum mengambil keputusan masuk ke pasar.

Algoritma berbasis Machine Learning dan Deep Learning

Kemajuan komputasi telah membawa perubahan signifikan dalam cara memproses, menganalisis, dan memprediksi perilaku pasar modal. Peningkatan kapasitas komputasi, ketersediaan data dalam skala besar, serta pengembangan algoritma canggih telah memungkinkan lahirnya pendekatan yang dapat belajar secara adaptif dari *big data*. Pendekatan

ini, yang berlandaskan pada *machine learning* (ML) dan *deep learning* (DL), memberikan fleksibilitas dalam mengenali hubungan non-linear dan kompleks antarvariabel, sehingga mampu menghasilkan keluaran dengan mutu yang lebih tinggi dibandingkan model linear tradisional.

Salah satu pendorong utama adopsi ML di sektor keuangan adalah keberhasilan arsitektur *deep learning* seperti *Long Short-Term Memory* (LSTM) dalam memproses data deret waktu yang fluktuatif. LSTM mampu mempertahankan informasi jangka panjang dan meminimalkan masalah *vanishing gradient* yang umum terjadi pada jaringan saraf konvensional. Keunggulan ini menjadikannya efektif dalam memprediksi pergerakan harga saham dan mengembangkan strategi perdagangan yang adaptif. Model seperti ini dapat menangkap pola yang tersembunyi dalam data, termasuk tren musiman, perubahan rezim pasar, maupun reaksi harga terhadap peristiwa eksternal.

Selain LSTM, arsitektur lain seperti *Convolutional Neural Networks* (CNN) dan *Recurrent Neural Networks* (RNN) juga memainkan peran penting. CNN, yang awalnya dirancang untuk pengenalan citra, telah dimodifikasi untuk menganalisis data pasar dengan mengubah deret waktu menjadi representasi spasial, sehingga pola lokal dapat diidentifikasi dengan presisi tinggi. Sementara itu, RNN unggul dalam memodelkan ketergantungan dinamis yang berubah seiring waktu. Penggabungan keduanya, bahkan dalam bentuk *hybrid models*, memungkinkan analisis yang lebih kaya dan komprehensif.

Integrasi *Natural Language Processing* (NLP) telah memperluas kemampuan analisis ke ranah data tak terstruktur. Informasi yang berasal dari berita, laporan keuangan, hingga percakapan di media sosial dapat diolah untuk mengekstrak sentimen pasar. Pendekatan ini penting karena

pergerakan harga tidak hanya dipengaruhi oleh data fundamental, tetapi juga oleh persepsi dan ekspektasi investor. *Sentiment analysis* berbasis NLP membantu mendeteksi perubahan psikologis pasar sebelum tercermin pada harga, sehingga memberikan keunggulan prediktif.

Pengembangan *reinforcement learning* (RL) juga menjadi lompatan besar. RL memungkinkan sistem untuk belajar dari interaksi dengan lingkungan pasar, memperbaiki strategi berdasarkan umpan balik dari hasil yang diperoleh. Algoritma RL mampu beradaptasi terhadap kondisi pasar yang berubah-ubah, memaksimalkan keuntungan, dan mengendalikan risiko secara bersamaan. Pendekatan ini menjadi dasar bagi banyak strategi perdagangan otonom yang digunakan oleh institusi keuangan besar.

Semua kemajuan ini dimungkinkan oleh infrastruktur komputasi modern seperti *Graphics Processing Units* (GPU) dan layanan *cloud computing*. Teknologi ini mempercepat proses pelatihan model dan memungkinkan pengolahan data dalam jumlah sangat besar secara real-time. Ketersediaan daya komputasi yang terjangkau dan fleksibel telah membuka peluang bagi pelaku pasar, baik individu maupun institusi, untuk mengimplementasikan model ML dan DL dalam skala yang sebelumnya sulit dicapai.

Selain itu, penggabungan konsep *big data*, komputasi awan, dan *deep learning* telah mengubah lanskap analisis keuangan secara fundamental. Volume data yang besar, baik terstruktur maupun tidak terstruktur, dapat diintegrasikan untuk menciptakan model yang lebih robust dan akurat. Hal ini mendukung pengambilan keputusan berbasis data yang lebih cepat dan presisi, serta meningkatkan kemampuan dalam mengantisipasi perubahan pasar yang cepat.

Meski menjanjikan, penerapan ML dan DL dalam keuangan tetap memerlukan pengelolaan yang hati-hati. Tantangan seperti *overfitting*, kebutuhan interpretabilitas, dan kualitas data menjadi faktor yang harus diatasi agar model dapat memberikan hasil yang konsisten. Pendekatan yang menggabungkan keunggulan teknis ML/DL dengan pemahaman mendalam tentang perilaku pasar akan menghasilkan sistem prediksi dan strategi investasi yang tangguh.

Keunggulan pendekatan modern

Pengujian berulang pada berbagai himpunan data menunjukkan bahwa pendekatan modern berbasis *artificial intelligence* (AI) memiliki keunggulan yang konsisten dalam hal ketepatan dan ketahanan. Berbeda dengan model klasik yang cenderung mengandalkan asumsi statis, model modern mampu beradaptasi secara dinamis terhadap perubahan struktur data dan kondisi lingkungan yang terus berkembang. Kemampuan ini memberikan keunggulan signifikan dalam pengambilan keputusan yang membutuhkan akurasi tinggi. Keberhasilan pendekatan modern sebagian besar dipengaruhi oleh kemampuannya mengintegrasikan sumber data yang beragam, termasuk data terstruktur, tidak terstruktur, dan semi-terstruktur. Misalnya, dalam sektor keuangan, model berbasis *machine learning* dapat menggabungkan data harga historis, laporan keuangan, dan analisis sentimen dari media sosial. Hal ini memungkinkan model tidak hanya mengidentifikasi pola historis, tetapi juga merespons perubahan sentimen pasar secara real time, menghasilkan prediksi yang lebih relevan dan tepat waktu. Ketahanan model modern terhadap *noise* dan anomali juga menjadi faktor pembeda. Melalui proses *training* yang ekstensif pada data


besar, model AI dapat mempelajari perbedaan antara sinyal yang bermakna dan gangguan yang menyesatkan. Algoritma seperti *ensemble learning* dan *deep neural networks* memperkuat kemampuan ini dengan menggabungkan kekuatan berbagai model untuk menghasilkan keluaran yang lebih stabil, bahkan ketika dihadapkan pada kondisi pasar yang volatil atau data yang tidak lengkap.

Keunggulan ini terbukti dalam berbagai pengujian lintas domain. Pada skenario kesehatan, misalnya, model prediktif berbasis AI mampu mengidentifikasi faktor risiko dengan akurasi lebih tinggi dibandingkan model statistik konvensional. Hasilnya adalah intervensi yang lebih cepat dan tepat sasaran. Di sektor manufaktur, algoritma AI digunakan untuk memprediksi kegagalan mesin sebelum terjadi, mengurangi biaya pemeliharaan dan menghindari penghentian produksi yang merugikan. Peningkatan kinerja ini diukur melalui berbagai metrik evaluasi, mulai dari *mean absolute error* (MAE) hingga *F1-score*, yang menunjukkan perbaikan signifikan pada sebagian besar skenario uji. Standarisasi metrik ini penting agar hasil dapat dibandingkan secara adil antar studi dan implementasi, memastikan bahwa klaim peningkatan performa benar-benar mencerminkan kemajuan teknologi dan bukan hanya perbedaan dalam metodologi pengukuran.

Penerapan uji coba berulang di berbagai himpunan data juga menggarisbawahi fleksibilitas model modern. Alih-alih mengalami penurunan performa saat dihadapkan pada data baru, model AI yang dirancang dengan baik mampu mempertahankan tingkat akurasi yang tinggi berkat mekanisme pembaruan parameter yang adaptif. Hal ini kontras dengan model klasik yang sering kali perlu diestimasi ulang secara menyeluruh ketika menghadapi dataset yang berbeda. Selain itu,

penerapan *transfer learning* memperluas kemampuan model modern untuk bekerja di berbagai domain tanpa memerlukan pelatihan ulang dari awal. Dengan memanfaatkan pengetahuan yang telah diperoleh dari dataset sebelumnya, model dapat mempercepat proses adaptasi pada dataset baru, menghemat sumber daya komputasi, dan mengurangi waktu yang dibutuhkan untuk mencapai performa optimal.

Keunggulan empiris ini bukan hanya soal kecepatan dan ketepatan, tetapi juga mencakup dimensi ketahanan terhadap bias data. Pendekatan modern sering kali menyertakan langkah-langkah untuk mendeteksi dan mengoreksi bias, memastikan bahwa prediksi yang dihasilkan tidak hanya akurat, tetapi juga adil bagi berbagai kelompok pengguna. Hal ini semakin relevan dalam penerapan di sektor publik dan kesehatan, di mana dampak keputusan dapat memengaruhi kehidupan banyak orang. Secara keseluruhan, bukti dari berbagai pengujian menunjukkan bahwa pendekatan modern berbasis AI mampu memberikan hasil yang lebih unggul dibandingkan pendekatan klasik, baik dalam ketepatan prediksi, ketahanan terhadap gangguan, maupun kemampuan adaptasi lintas domain. Keunggulan ini diperkuat oleh kemajuan dalam komputasi, ketersediaan data besar, dan pengembangan algoritma yang semakin canggih, menjadikannya pilihan utama dalam pemodelan dan pengambilan keputusan di era data saat ini.



Gambar 7. Perbandingan Kinerja Model *SVR* untuk Prediksi Harga Saham

Gambar ini memperlihatkan diagram batang yang membandingkan kinerja tiga varian *Support Vector Regression* (*SVR*) dalam memprediksi harga saham. Sumbu vertikal menunjukkan tingkat kinerja (*performance*) dalam skala numerik, sedangkan sumbu horizontal menampilkan tiga kategori model yang diuji. Batang pertama, berwarna merah, merepresentasikan **SVR-TI** yang menggunakan *technical indicators* sebagai masukan utama. Nilai kinerjanya berada sedikit di atas 1200, menandakan performa yang stabil dan cukup kompetitif meski tidak menjadi yang tertinggi. Batang kedua, berwarna oranye, menggambarkan **SVR-rVMF** yang mengandalkan pendekatan berbasis *von Mises-Fisher distribution* dalam mengolah informasi. Model ini memperoleh hasil tertinggi, berada di kisaran 1500.

Pencapaian ini menunjukkan kemampuan model tersebut dalam menangkap pola data yang relevan, sehingga mampu menghasilkan prediksi dengan akurasi yang lebih baik. Batang ketiga, berwarna krem, merepresentasikan **SVR-TI-rVMF**, kombinasi antara *technical indicators*

dan *von Mises–Fisher distribution*. Menariknya, kinerja gabungan ini berada di bawah 1000, lebih rendah dibanding dua model lainnya. Fenomena ini mengindikasikan bahwa penggabungan dua pendekatan tidak selalu memberikan hasil yang lebih baik, bahkan berpotensi menurunkan kinerja jika integrasi komponen tidak selaras. Perbandingan ini memberikan gambaran bahwa pemilihan pendekatan pemrosesan data dan variabel masukan sangat memengaruhi hasil prediksi harga saham. Pencapaian tinggi pada SVR-rVMF menegaskan pentingnya kesesuaian teknik dengan karakteristik data, sedangkan hasil pada SVR-TI-rVMF mengingatkan bahwa kombinasi fitur memerlukan perancangan yang cermat untuk memastikan sinergi yang efektif.

Bab 4. Arsitektur Deep Learning Untuk Data Time Series

Peran CNN dalam mengenali pola

Convolutional Neural Networks (CNN) awalnya dikembangkan untuk pengolahan citra, namun prinsip dasarnya yang memanfaatkan *convolutional filters* telah berhasil diadaptasi untuk data *time series*. Pada data berdimensi satu, CNN menerapkan serangkaian *filters* yang dapat dipelajari pada jendela geser (*sliding window*) dari urutan data. Proses konvolusi ini memungkinkan model untuk menangkap pola lokal seperti tren singkat, lonjakan, atau osilasi, yang kemudian diubah menjadi *feature maps* yang menyoroti ketergantungan temporal berskala lokal. Representasi ini dapat diproses lebih lanjut atau digabungkan untuk membentuk abstraksi tingkat lebih tinggi. Kelebihan utama CNN terletak pada kemampuannya mendeteksi pola berulang dan mikro-pola tanpa bergantung pada posisi spesifik di dalam urutan data. Dengan sifat *weight sharing* dan konektivitas yang jarang (*sparse connectivity*), CNN dapat secara efisien mengenali pola lokal di berbagai bagian urutan, mengatasi keterbatasan pendekatan *sliding window* konvensional. Kemampuan ini sangat penting ketika bekerja dengan data yang memiliki dinamika singkat namun bermakna, seperti pergerakan harga saham yang volatil atau sinyal sensor yang cepat berubah.

Lapisan konvolusi dalam CNN secara inheren mengekstrak fitur lokal dengan mempelajari *kernels* yang merespons karakteristik sinyal jangka pendek, seperti perubahan amplitudo mendadak atau peristiwa transien. Pendekatan ini mengurangi kebutuhan rekayasa fitur manual

(*manual feature engineering*), sekaligus meningkatkan kepekaan terhadap dinamika jangka pendek. Dalam ranah keuangan, misalnya, perubahan harga yang terjadi dalam interval waktu singkat dapat menjadi indikasi awal pergeseran tren pasar atau anomali yang signifikan.

Penggunaan CNN dalam pengolahan *time series* telah menghasilkan berbagai model yang unggul dalam memprediksi pola jangka pendek. Salah satu penerapannya terlihat pada prediksi indeks pengiriman kontainer, di mana CNN digunakan untuk mengekstrak ciri lokal yang mencerminkan momentum dan volatilitas pasar secara langsung. Pendekatan ini meningkatkan relevansi prediksi dengan memanfaatkan sinyal yang muncul pada periode waktu terbatas namun memiliki dampak besar pada keputusan bisnis. Dalam tugas prediksi pasar saham, CNN sering dikombinasikan dengan teknik lain untuk memperluas kemampuannya. Salah satu strategi yang umum digunakan adalah mengubah data *time series* menjadi representasi *image-like* atau matriks, sehingga CNN dapat mengidentifikasi pola seperti pada data citra. Transformasi ini memudahkan model mengenali keterkaitan temporal dan hubungan antar variabel secara simultan, menghasilkan peningkatan akurasi prediksi.

Keunggulan CNN semakin terlihat ketika digabungkan dengan arsitektur lain seperti *Long Short-Term Memory* (LSTM) dalam model hibrida. CNN bertugas mengekstrak fitur lokal jangka pendek, sedangkan LSTM mengelola ketergantungan jangka panjang. Kombinasi ini memungkinkan sistem untuk menangkap fluktuasi cepat sekaligus mempertahankan informasi yang relevan dari periode sebelumnya, membentuk kerangka prediksi yang lebih tangguh terhadap variasi data.

Pendekatan hibrida ini juga memperluas fleksibilitas CNN untuk diaplikasikan di berbagai domain. Dalam sistem prediksi berbasis data sensor industri, CNN dapat mengenali pola mikro yang mengindikasikan awal kerusakan komponen, sementara LSTM memastikan bahwa tren perubahan performa komponen tetap dipantau. Dalam bidang kesehatan, CNN dapat mengidentifikasi anomali singkat pada sinyal EKG, sedangkan LSTM melacak evolusi kondisi pasien dari waktu ke waktu.

Selain keunggulan teknis, penggunaan CNN pada *time series* memberikan efisiensi komputasi karena sifat *parallelizable* dari operasi konvolusi. Hal ini memungkinkan pelatihan model dilakukan lebih cepat dibandingkan arsitektur yang sepenuhnya bergantung pada pemrosesan berurutan seperti RNN, terutama ketika menggunakan sumber daya komputasi modern seperti GPU. Efisiensi ini membuka peluang untuk pengolahan data dalam skala besar secara real-time, yang sangat bermanfaat dalam pengambilan keputusan yang memerlukan respons cepat.


Tabel 6. Parameter CNN yang Lazim untuk Analisis Time Series

Parameter	Deskripsi Singkat	Contoh Nilai Tipikal
Jumlah lapisan	Banyaknya layer konvolusi, pooling, dan dense dalam arsitektur CNN.	2–4 lapisan konvolusi + 1–2 dense
Jumlah & ukuran filter	Banyak filter dan ukuran kernel memengaruhi cakupan temporal fitur.	32–128 filter, kernel size 3–7
Dilation	Memperluas jangkauan filter tanpa menambah ukuran kernel.	1, 2, 4 (bertingkat)
Stride	Jarak perpindahan filter, memengaruhi resolusi output.	1 atau 2

Padding	Penambahan nilai nol agar panjang output sesuai kebutuhan.	'same' atau 'valid'
Pooling (jenis & ukuran)	Mereduksi dimensi dan mengekstrak fitur dominan.	Max pooling, ukuran 2
Fungsi aktivasi	Non-linearitas seperti ReLU, sigmoid, atau tanh.	ReLU
Batch size	Ukuran batch saat pelatihan, memengaruhi konvergensi.	32–128
Learning rate & optimizer	Kecepatan pembaruan bobot dan algoritma optimisasi.	Adam, LR=0.001–0.01
Input channels & window length	Banyak channel input dan panjang jendela waktu.	1–10 channel, 24–168 timestep
Dropout	Menonaktifkan neuron secara acak untuk mencegah overfitting.	0.1–0.3
Context length	Panjang historis input sebelum prediksi.	2–12 × horizon prediksi

Tabel ini menyajikan parameter inti dalam pengembangan *Convolutional Neural Network* (CNN) untuk analisis *time series* beserta contoh nilai yang umum digunakan sebagai titik awal (*baseline*) pada proses *hyperparameter tuning*. Jumlah lapisan dan konfigurasi filter sangat menentukan kedalaman representasi fitur dan jangkauan temporal yang tertangkap. *Dilation*, *stride*, dan *padding* digunakan untuk mengatur cakupan pola serta mempertahankan ukuran output. Pooling membantu menyederhanakan representasi dengan tetap mempertahankan informasi utama. Pemilihan fungsi aktivasi seperti ReLU umum digunakan karena stabil dan efektif untuk data numerik kontinu. Parameter *batch size* serta kombinasi *learning rate* dan *optimizer*

berpengaruh langsung pada stabilitas dan kecepatan pelatihan. Panjang jendela input (*window length*) dan jumlah kanal (*channels*) menyesuaikan sifat data, baik univariat maupun multivariat. Dropout penting untuk mengurangi overfitting pada dataset dengan ukuran terbatas. Khusus arsitektur tertentu seperti CNN-QR, *context length* menjadi faktor utama dalam menentukan seberapa jauh data historis digunakan untuk prediksi. Nilai tipikal yang ditampilkan di tabel ini bersifat panduan awal; penyesuaian akhir tetap harus melalui proses eksperimen terkontrol menggunakan *validation set*. Dengan memahami dan mengatur parameter-parameter ini secara tepat, model CNN dapat dioptimalkan untuk berbagai aplikasi peramalan seperti energi, cuaca, keuangan, dan permintaan pasar.



Gambar 8. Skema *Gradient Convolution Filter* pada Sinyal Harga

Gambar ini memperlihatkan proses penerapan *gradient convolution filter* terhadap sinyal harga berbentuk *time series*. Garis berwarna biru menggambarkan pergerakan harga asli dari waktu ke waktu, sedangkan garis merah menunjukkan hasil konvolusi yang

diperoleh setelah sinyal harga diproses menggunakan filter dengan bobot $-1, -1, 0, 1, 1, -1, -1, 0, 1, 1$. Filter ini dirancang untuk merespons perubahan arah harga, baik lonjakan ke atas maupun penurunan tajam. Prosesnya dilakukan dengan menggeser filter sepanjang sinyal harga dan menghitung *dot product* pada setiap posisi. Hasil positif pada keluaran konvolusi mengindikasikan adanya pergerakan harga yang cenderung naik, sementara hasil negatif menunjukkan arah penurunan. Dengan demikian, garis merah yang berada di atas garis nol dapat diartikan sebagai sinyal awal dari tren kenaikan, sedangkan garis di bawah nol mengisyaratkan kemungkinan penurunan.

Skala pada sumbu kiri menggambarkan nilai asli *time series*, sementara sumbu kanan digunakan untuk skala hasil konvolusi. Terlihat bahwa puncak pada garis merah muncul lebih awal dibandingkan puncak pada garis biru. Hal ini memberikan petunjuk bahwa filter mampu mengenali percepatan kenaikan harga sebelum mencapai titik tertingginya. Pendekatan visual seperti ini bermanfaat untuk mengungkap pola pergerakan harga yang tersembunyi di dalam data. Dengan menggabungkan teknik *feature extraction* dan pemodelan berbasis *Convolutional Neural Network*, skema ini dapat digunakan untuk mendeteksi tren, memprediksi perubahan harga, atau mengidentifikasi kejadian tak biasa pada beragam bidang, mulai dari pasar keuangan hingga sistem pemantauan industri.

Kemampuan GRU dalam memahami hubungan temporal

Gated Recurrent Unit (GRU) merupakan salah satu varian recurrent neural network (RNN) yang dirancang untuk mengatasi keterbatasan dalam memproses data urutan panjang, khususnya permasalahan

vanishing gradient. Arsitektur ini memanfaatkan dua mekanisme gerbang utama, yaitu update gate dan reset gate, yang bekerja secara sinergis untuk mengatur aliran informasi sepanjang urutan data. Melalui mekanisme ini, GRU dapat menentukan informasi mana yang perlu dipertahankan dari masa lalu dan mana yang harus diperbarui dengan informasi baru, sehingga mampu menangkap baik fluktuasi jangka pendek maupun tren jangka panjang.

Update gate mengontrol seberapa besar proporsi informasi lama yang akan dipertahankan dalam keadaan tersembunyi (*hidden state*) saat menerima masukan baru. Dengan demikian, informasi yang relevan dari langkah sebelumnya dapat disimpan untuk digunakan pada langkah-langkah selanjutnya. Sementara itu, *reset gate* berperan dalam mengatur seberapa besar pengaruh informasi masa lalu terhadap perhitungan keadaan saat ini, yang memungkinkan model untuk melupakan informasi yang tidak lagi relevan. Kombinasi kedua gerbang ini membuat GRU lebih efisien dalam melakukan seleksi memori, mengurangi risiko mempertahankan *noise* atau pola yang tidak penting.

Keunggulan GRU dibandingkan LSTM terletak pada kesederhanaan arsitekturnya. Dengan menggabungkan fungsi *forget gate* dan *input gate* menjadi satu *update gate*, serta menyatukan *cell state* dengan *hidden state*, GRU memiliki jumlah parameter yang lebih sedikit. Hal ini menghasilkan waktu pelatihan yang lebih singkat dan kebutuhan komputasi yang lebih rendah, menjadikannya pilihan yang tepat untuk aplikasi dengan keterbatasan sumber daya atau kebutuhan *real-time forecasting*. Studi terbaru menunjukkan bahwa dalam banyak tugas peramalan, khususnya di sektor keuangan, GRU mampu

memberikan kinerja setara bahkan melampaui LSTM, terutama ketika efisiensi dan kecepatan menjadi prioritas utama.

Kemampuan GRU untuk mempertahankan gradien selama proses *backpropagation through time* (BPTT) menjadi faktor penting dalam keberhasilannya mengatasi *vanishing gradient problem*. Dengan regulasi memori yang dikendalikan oleh *update gate*, gradien tidak mengalami penurunan drastis saat memproses urutan panjang. Hal ini sangat penting dalam analisis data keuangan, di mana efek suatu peristiwa dapat muncul secara tertunda, dan model perlu mengingat informasi yang relevan untuk jangka waktu yang lama. Penerapan GRU dalam pemodelan data *time series* telah terbukti efektif di berbagai domain. Dalam peramalan harga saham, misalnya, GRU dapat memanfaatkan pola pergerakan harga historis sekaligus bereaksi terhadap perubahan pasar terkini. Dengan memproses sinyal keuangan secara berurutan, model mampu mengenali hubungan temporal yang kompleks antara peristiwa pasar, berita ekonomi, dan reaksi investor. Hal ini memberikan keunggulan dalam menghasilkan prediksi yang lebih akurat dan relevan dibandingkan metode statistik tradisional.

Keberhasilan GRU juga terlihat pada integrasinya dengan model lain dalam kerangka *hybrid architecture*. Menggabungkan GRU dengan *convolutional neural network* (CNN) memungkinkan ekstraksi fitur lokal yang kuat dari data sebelum dimodelkan secara temporal. Pendekatan ini mengoptimalkan kemampuan model dalam mengenali pola jangka pendek sekaligus menjaga konsistensi prediksi dalam jangka panjang. Hasilnya adalah sistem peramalan yang lebih tangguh terhadap volatilitas pasar dan *noise* dalam data. Selain di bidang keuangan, GRU telah digunakan secara luas dalam analisis deret waktu di sektor kesehatan,

logistik, dan pengelolaan energi. Dalam sistem pemantauan kesehatan, GRU membantu memprediksi kondisi pasien berdasarkan data sensor medis yang kontinu, mempertahankan informasi kritis seperti tren perubahan detak jantung atau pola pernapasan. Pada sektor energi, GRU digunakan untuk memprediksi beban listrik harian dengan mempertimbangkan pola musiman dan peristiwa khusus, yang membantu operator dalam perencanaan distribusi daya.

Efisiensi GRU dalam pengolahan data urutan membuatnya relevan dalam aplikasi *real-time*, seperti sistem perdagangan algoritmik (*algorithmic trading*) yang memerlukan respons cepat terhadap perubahan pasar. Dengan latensi rendah dalam pengambilan keputusan, GRU dapat mengolah data masuk secara terus menerus dan memperbarui prediksi dalam hitungan milidetik, memberikan keunggulan kompetitif bagi pelaku pasar. Kemampuan GRU untuk menjaga informasi relevan sepanjang urutan dan melakukan seleksi memori yang efisien melalui mekanisme gerbangnya menjadikannya salah satu arsitektur *deep learning* yang sangat efektif untuk pemodelan data *time series*. Sifatnya yang ringkas namun tangguh, dikombinasikan dengan kemampuan mengatasi *vanishing gradient*, membuat GRU menjadi pilihan unggulan dalam berbagai aplikasi prediktif, khususnya di lingkungan yang dinamis dan memerlukan adaptasi cepat terhadap perubahan kondisi.

Tabel 7. Perbandingan LSTM vs GRU

Aspek	LSTM	GRU
Arsitektur Gerbang	Memiliki tiga gerbang: <i>input gate</i> , <i>forget gate</i> , dan <i>output gate</i> . Masing-masing memiliki fungsi spesifik dalam mengatur aliran informasi di jaringan.	Memiliki dua gerbang: <i>update gate</i> dan <i>reset gate</i> , yang menggabungkan sebagian fungsi gerbang LSTM sehingga arsitekturnya lebih sederhana.

Jumlah Parameter	Lebih banyak parameter karena adanya tiga gerbang, sel memori terpisah, dan persamaan yang lebih kompleks.	Lebih sedikit parameter, sehingga proses pelatihan lebih cepat dan penggunaan memori lebih efisien.
Ketahanan Jangka Panjang	Sangat baik dalam menangani ketergantungan jangka panjang (<i>long-term dependencies</i>) berkat keberadaan sel memori khusus.	Baik dalam menangani ketergantungan jangka panjang, tetapi terkadang kurang akurat untuk urutan yang sangat panjang dan kompleks.
Efisiensi Komputasi	Lebih lambat untuk dilatih dan dieksekusi karena kompleksitas arsitektur dan jumlah parameter yang lebih besar.	Lebih cepat dalam pelatihan dan prediksi karena struktur yang lebih ringkas dan jumlah parameter lebih sedikit.
Kemampuan Generalisasi	Mampu menangani data dengan pola yang sangat kompleks dan bervariasi, termasuk sinyal yang memiliki banyak tingkat variabilitas.	Cenderung unggul pada data yang polanya tidak terlalu rumit dan urutannya relatif pendek hingga menengah.
Penggunaan Memori	Membutuhkan memori yang lebih besar untuk menyimpan parameter dan status jaringan selama pelatihan maupun inferensi.	Membutuhkan memori lebih sedikit, cocok untuk implementasi pada perangkat dengan keterbatasan sumber daya.
Kinerja Umum	Sering kali unggul dalam aplikasi seperti pemrosesan bahasa alami (<i>NLP</i>), pengenalan suara, dan prediksi deret waktu yang sangat kompleks.	Memberikan performa yang kompetitif dengan LSTM pada banyak aplikasi, sering kali tanpa perbedaan signifikan dalam akurasi, namun lebih efisien.
Kesesuaian Penggunaan	Direkomendasikan untuk kasus yang membutuhkan akurasi tinggi pada urutan panjang, atau di mana kehilangan informasi jangka panjang harus diminimalkan.	Cocok untuk kasus dengan keterbatasan waktu pelatihan atau sumber daya, dan untuk data dengan urutan yang relatif lebih sederhana.

Tabel ini menyajikan perbandingan mendalam antara dua arsitektur populer dalam pemrosesan deret waktu dan data sekuensial, yaitu *Long Short-Term Memory (LSTM)* dan *Gated Recurrent Unit (GRU)*. Keduanya merupakan pengembangan dari jaringan saraf *Recurrent Neural Network (RNN)* yang dirancang untuk mengatasi kelemahan utama RNN konvensional, yaitu *vanishing gradient problem*, yang membuat jaringan sulit mempelajari ketergantungan jangka panjang. Dari segi arsitektur gerbang, LSTM memiliki tiga komponen pengendali utama: *input gate*, *forget gate*, dan *output gate*. Masing-masing gerbang berperan dalam memutuskan informasi mana yang harus disimpan, dihapus, atau dikeluarkan pada setiap langkah waktu. Kehadiran sel memori terpisah memungkinkan LSTM mempertahankan informasi dalam jangka panjang tanpa mudah terhapus oleh pembaruan data baru. Sementara itu, GRU menyederhanakan mekanisme ini dengan hanya menggunakan dua gerbang: *update gate* yang mengontrol seberapa besar informasi masa lalu dipertahankan, dan *reset gate* yang menentukan seberapa besar informasi lama akan dilupakan. Penyederhanaan ini mengurangi kompleksitas jaringan, membuatnya lebih ringan secara komputasi.


Jumlah parameter pada LSTM lebih besar dibandingkan GRU. Hal ini disebabkan oleh adanya lebih banyak persamaan dan variabel internal yang perlu dioptimalkan selama pelatihan. Setiap gerbang dalam LSTM memerlukan bobot dan bias sendiri, sehingga beban memori dan waktu komputasi meningkat. GRU, dengan dua gerbangnya, memangkas kebutuhan parameter ini, sehingga pelatihan bisa dilakukan lebih cepat dan dengan kebutuhan memori yang lebih rendah. Keunggulan ini membuat GRU menjadi pilihan menarik untuk lingkungan dengan sumber

daya terbatas atau ketika waktu pelatihan menjadi faktor penting. Ketahanan jangka panjang merupakan salah satu keunggulan utama LSTM. Berkat desain sel memorinya, LSTM mampu mempertahankan informasi penting dari input yang sangat lama jaraknya dalam urutan data, sebuah kemampuan yang sangat bermanfaat dalam pemrosesan bahasa atau analisis sinyal yang memiliki pola jangka panjang. GRU juga mampu mempertahankan informasi untuk periode yang cukup panjang, namun pada urutan yang sangat panjang dan kompleks, kinerjanya kadang tidak setangguh LSTM.

Efisiensi komputasi menjadi salah satu faktor pembeda terbesar di antara keduanya. Kompleksitas arsitektur LSTM membuatnya memerlukan waktu pelatihan yang lebih lama, apalagi pada dataset besar dengan urutan panjang. Sebaliknya, GRU dengan struktur lebih sederhana menawarkan pelatihan dan inferensi yang lebih cepat. Hal ini menjadi keunggulan signifikan terutama dalam pengembangan model yang harus diperbarui secara berkala atau dijalankan pada sistem real-time. Dari sisi kemampuan generalisasi, LSTM cenderung unggul pada data dengan pola yang kompleks dan tidak beraturan. Misalnya, pada teks atau sinyal suara yang mengandung banyak nuansa dan variasi, LSTM mampu menangkap perbedaan halus yang mungkin diabaikan oleh GRU. Namun, untuk data dengan pola yang lebih sederhana atau urutan pendek hingga menengah, GRU sering memberikan hasil yang setara, bahkan terkadang lebih baik, karena tidak “terlalu mempelajari” noise pada data. Penggunaan memori menjadi pertimbangan penting dalam implementasi praktis. LSTM memerlukan kapasitas memori yang lebih besar untuk menyimpan parameter, status jaringan, dan data intermediate selama pelatihan. Hal ini membuatnya kurang cocok untuk

perangkat dengan kapasitas terbatas seperti *embedded systems* atau aplikasi pada ponsel pintar dengan sumber daya terbatas. GRU, yang memerlukan memori lebih sedikit, menjadi alternatif yang efisien dalam skenario ini.

Jika dilihat dari kinerja umum, keduanya memiliki area di mana mereka unggul. LSTM sering menjadi pilihan utama untuk pemrosesan bahasa alami (*Natural Language Processing*), pengenalan suara (*speech recognition*), dan prediksi deret waktu dengan kompleksitas tinggi seperti data keuangan jangka panjang. GRU, dengan efisiensinya, banyak digunakan dalam aplikasi real-time, prediksi jangka pendek, atau proyek yang memerlukan pembaruan model secara cepat. Akhirnya, dalam hal kesesuaian penggunaan, LSTM lebih direkomendasikan untuk kasus yang memerlukan retensi informasi jangka panjang dengan akurasi tinggi. Model ini unggul ketika kehilangan informasi masa lalu dapat berpengaruh besar pada hasil prediksi. Di sisi lain, GRU menjadi pilihan tepat ketika kecepatan dan efisiensi sumber daya menjadi prioritas, terutama jika data tidak memerlukan pemrosesan pola yang terlalu kompleks. Kedua model ini tetap relevan dalam pengembangan sistem cerdas berbasis data sekuensial. Pilihan di antara keduanya sebaiknya mempertimbangkan keseimbangan antara akurasi, kecepatan, ketersediaan sumber daya, serta karakteristik data yang dihadapi. Dalam beberapa kasus, uji coba pada kedua arsitektur ini secara langsung menjadi pendekatan yang bijak untuk menentukan model yang paling optimal bagi kebutuhan spesifik.



Gambar 9. Diagram Gerbang pada *Gated Recurrent Unit* (GRU)

Gambar ini memperlihatkan alur kerja internal dari sebuah *Gated Recurrent Unit*, yang dirancang untuk mengolah data berurutan dengan efisien. Struktur ini terdiri dari dua komponen utama yang disebut *reset gate* dan *update gate*, yang berfungsi sebagai pengatur arus informasi antara memori lama dan informasi baru. Kedua gerbang ini bekerja sama untuk menentukan apakah informasi dari langkah sebelumnya akan dipertahankan, diubah, atau digantikan oleh informasi yang datang dari input terbaru. Proses dimulai ketika data dari langkah sebelumnya dan input saat ini memasuki sistem. *Reset gate* berperan sebagai pengendali yang menentukan bagian mana dari memori lama yang perlu diabaikan, sehingga unit dapat lebih fokus pada informasi yang relevan. Sementara itu, *update gate* mengatur keseimbangan antara mempertahankan memori lama dan menerima pembaruan dari informasi baru. Dengan cara ini, unit dapat beradaptasi terhadap perubahan pola tanpa kehilangan detail penting dari masa lalu.

Diagram juga menampilkan *candidate hidden state*, yang merupakan hasil pemrosesan informasi baru setelah disaring oleh *reset*

gate. Nilai ini kemudian dikombinasikan dengan memori lama menggunakan pengaturan dari *update gate* untuk menghasilkan *hidden state* terbaru. Simbol-simbol dalam gambar membantu menjelaskan fungsi tiap bagian, seperti operasi gabungan, penjumlahan, dan aktivasi non-linear yang menjaga kestabilan pembelajaran. Dengan mekanisme ini, GRU mampu mempertahankan informasi yang relevan dalam jangka waktu panjang sekaligus merespons dinamika baru pada data. Sifatnya yang lebih sederhana dibandingkan model serupa membuat GRU banyak digunakan pada aplikasi yang memerlukan pemrosesan cepat, mulai dari prediksi deret waktu, pemrosesan bahasa alami, hingga pengenalan pola dalam sinyal kompleks. Desain yang ringkas namun adaptif ini menjadikan GRU salah satu pilihan yang efektif dalam mengelola data sekuensial di berbagai bidang.

Keunggulan BiGRU dalam pemrosesan dua arah


Pemrosesan dua arah pada *Recurrent Neural Network (RNN)* yang diimplementasikan dalam *Bidirectional Gated Recurrent Unit (BiGRU)* menawarkan keunggulan signifikan dalam menangkap hubungan temporal dibandingkan model searah. Arsitektur ini memanfaatkan dua lapisan *GRU* terpisah yang bekerja secara paralel: satu memproses data mengikuti urutan alami (*forward direction*), sedangkan yang lain memprosesnya dalam urutan terbalik (*backward direction*). Pendekatan ini memungkinkan model menggabungkan informasi dari masa lalu dan masa depan, sehingga menghasilkan representasi temporal yang lebih menyeluruh. Konteks ganda yang dihasilkan dari pemrosesan dua arah menjadi sangat berharga ketika pemaknaan suatu kejadian dipengaruhi

oleh peristiwa sebelumnya dan sesudahnya. Dalam pemodelan *time series* seperti prediksi beban listrik, pengamatan arus lalu lintas, dan perkiraan harga saham, pemanfaatan sinyal masa depan bersamaan dengan tren historis memberikan peningkatan akurasi sekaligus kestabilan prediksi. Dalam bidang *Natural Language Processing (NLP)*, kemampuan ini memungkinkan penangkapan makna kata secara lebih tepat, karena mempertimbangkan kata yang muncul sebelum dan sesudah istilah kunci, sehingga mendukung kinerja pada tugas seperti *sentiment analysis* maupun *named entity recognition*.

Manfaat *bidirectional processing* juga terlihat dalam aplikasi lain, termasuk pengenalan emosi berbasis sinyal *Electroencephalogram (EEG)* dan *motion capture* pada *bioengineering*. Pada studi berbasis EEG, BiGRU memanfaatkan dinamika sinyal sebelum dan sesudah titik pengamatan untuk memperkuat deteksi pola yang memiliki ketergantungan jangka panjang. Sementara itu, pada sistem *motion capture*, arsitektur ini mempermudah pemulihan lintasan penanda optik yang hilang dengan akurasi lebih tinggi. Peningkatan kinerja BiGRU dibandingkan model searah dapat ditelusuri dari kemampuannya melakukan *encoding* konteks yang lebih kaya. Model searah terbatas pada informasi historis untuk memprediksi atau mengklasifikasikan peristiwa saat ini, sedangkan BiGRU mengintegrasikan informasi masa lalu dan masa depan secara bersamaan. Hal ini berdampak pada penurunan metrik kesalahan seperti *Root Mean Squared Error (RMSE)* dan *Mean Absolute Error (MAE)* di berbagai pengujian.

Pada berbagai domain, BiGRU secara konsisten menunjukkan performa unggul, baik digunakan secara mandiri maupun dikombinasikan dengan *attention mechanism*. Integrasi mekanisme perhatian ini

memperkuat fokus model pada bagian urutan yang paling relevan, sehingga memperkaya representasi fitur. Dalam lingkungan yang kompleks seperti pasar energi atau jaringan lalu lintas perkotaan, kemampuan ini membantu menghasilkan keputusan yang lebih cepat dan tepat. Kekuatan BiGRU terletak pada kemampuannya memproses informasi secara dua arah, menangkap spektrum penuh ketergantungan temporal, serta memberikan pemahaman yang lebih peka terhadap perubahan pola. Penerapannya di berbagai bidang, mulai dari NLP, peramalan deret waktu, hingga analisis data sensor, menunjukkan bahwa BiGRU adalah pilihan arsitektur yang relevan untuk tugas-tugas yang membutuhkan pemodelan urutan secara mendalam dan menyeluruh.



Gambar 10. Arsitektur BiGRU Dua Arah

Gambar ini menampilkan representasi visual dari arsitektur *Bidirectional Gated Recurrent Unit* (BiGRU) yang bekerja dalam dua arah pemrosesan data. Arsitektur ini dirancang untuk mengolah informasi berurutan dengan memanfaatkan dua jalur pemrosesan paralel: satu jalur membaca urutan data dari awal hingga akhir (*forward direction*), sementara jalur lainnya membaca data dari akhir ke awal (*backward direction*). Proses dimulai dari bagian bawah diagram, yang menampilkan *embedding layer*. Lapisan ini berfungsi mengubah data mentah—seperti kata, karakter, atau simbol—menjadi representasi vektor yang dapat diproses oleh jaringan. Tiap lingkaran biru menggambarkan unit embedding yang memuat representasi numerik dari elemen urutan masukan. Setelah embedding terbentuk, data dikirim ke dua lapisan GRU yang berjalan bersamaan. Jalur berwarna biru tua di bagian bawah menandakan arah pemrosesan maju, memproses data dari kiri ke kanan mengikuti urutan alami. Sementara itu, jalur berwarna ungu di bagian atas mewakili arah pemrosesan mundur, memproses data dari kanan ke kiri. Pemrosesan dua arah ini memungkinkan model untuk menangkap informasi dari masa lalu dan masa depan pada setiap titik dalam urutan.

Setiap kotak pada kedua jalur ini merepresentasikan sebuah unit GRU. Unit GRU memiliki mekanisme internal berupa gerbang yang mengatur aliran informasi, memastikan hanya informasi relevan yang disimpan dan informasi kurang penting diabaikan. Dengan memproses data dari dua arah, model dapat menyimpan konteks lebih luas daripada GRU satu arah. Di bagian tengah atas diagram, terlihat proses penggabungan atau *concatenation* dari keluaran dua jalur tersebut. *Concatenation* menggabungkan hasil dari arah maju dan arah mundur menjadi satu representasi yang lebih kaya. Representasi gabungan ini

memuat konteks penuh dari data yang telah dianalisis, sehingga memberikan pemahaman yang lebih mendalam terhadap hubungan antar elemen urutan.

Keuntungan utama dari pendekatan ini adalah kemampuannya menangkap informasi yang berada di luar jangkauan langsung suatu titik dalam urutan. Dalam model satu arah, setiap posisi hanya dapat memanfaatkan informasi dari satu sisi (masa lalu atau masa depan). Sebaliknya, BiGRU mengombinasikan keduanya, memberikan pandangan menyeluruh yang sangat bermanfaat dalam pemrosesan bahasa alami, analisis teks, pengenalan ucapan, serta tugas lain yang memerlukan pemahaman konteks penuh. Struktur dua arah juga membantu saat model perlu memahami dependensi jangka panjang. Misalnya, dalam teks, arti sebuah kata sering kali dipengaruhi oleh kata-kata sebelum dan sesudahnya. Dengan memproses data dari kedua arah, BiGRU dapat menangkap hubungan seperti ini lebih efektif. Hal ini juga berlaku pada data deret waktu yang kompleks, di mana peristiwa di masa depan dapat membantu menginterpretasikan kejadian sebelumnya.

Selain keunggulan dalam memahami konteks, BiGRU juga menawarkan efisiensi dibandingkan model lain yang memiliki kompleksitas lebih tinggi. Meskipun memiliki dua jalur pemrosesan, desain GRU yang lebih sederhana daripada LSTM membuatnya lebih ringan secara komputasi, sehingga cocok untuk aplikasi yang memerlukan waktu pemrosesan cepat atau memiliki keterbatasan sumber daya. Diagram ini secara visual membantu memahami peran masing-masing komponen. Lapisan embedding mempersiapkan data mentah untuk diolah. Dua jalur GRU memastikan bahwa informasi diproses dari dua sudut pandang temporal. Proses *concatenation* menggabungkan hasil

tersebut untuk membentuk representasi akhir yang siap digunakan pada tahap selanjutnya, seperti klasifikasi, prediksi, atau pembuatan keluaran teks.

Penerapan arsitektur ini sangat luas. Dalam pengolahan bahasa alami, BiGRU digunakan untuk tugas seperti penerjemahan mesin, analisis sentimen, atau ringkasan teks, di mana pemahaman konteks penuh sangat penting. Dalam pengenalan ucapan, model ini membantu mengenali kata secara akurat dengan mempertimbangkan bunyi sebelum dan sesudah. Dalam pengolahan sinyal atau deret waktu, BiGRU dapat meningkatkan akurasi prediksi dengan memanfaatkan informasi yang terjadi di kedua arah waktu. Keunggulan lainnya adalah fleksibilitas dalam integrasi. BiGRU dapat digabungkan dengan lapisan konvolusi untuk menangkap pola spasial sekaligus temporal, atau digunakan bersama mekanisme perhatian (*attention mechanism*) untuk fokus pada bagian tertentu dari urutan yang paling relevan dengan tugas yang dihadapi.

Sinergi CNN dan BiGRU dalam model hibrid


Model *hybrid* yang menggabungkan *Convolutional Neural Networks* (CNN) dan *Bidirectional Gated Recurrent Units* (BiGRU) menghadirkan kombinasi yang selaras antara kemampuan ekstraksi fitur spasial dan pemahaman urutan temporal. CNN berperan dalam menangkap ciri-ciri lokal dari data mentah melalui operasi konvolusi dan *pooling*, yang memudahkan identifikasi pola penting serta mengurangi *noise* tanpa kehilangan informasi utama. Pendekatan ini memungkinkan data diolah menjadi representasi yang ringkas namun tetap kaya akan informasi yang relevan. BiGRU kemudian mengambil alih dengan

memproses representasi tersebut secara dua arah, baik dari masa lalu menuju masa depan (*forward direction*) maupun sebaliknya (*backward direction*). Kemampuan ini memberi BiGRU kekuatan untuk mengaitkan informasi historis dengan sinyal yang akan datang, sehingga hubungan temporal yang kompleks dapat dipahami secara lebih menyeluruh. Hasilnya adalah model yang mampu mengenali pola jangka pendek sekaligus mempertahankan pemahaman terhadap tren jangka panjang.

Proses dalam arsitektur ini berjalan dalam dua tahap yang saling melengkapi. Tahap pertama memanfaatkan CNN untuk mengekstraksi fitur lokal, menyoroti area yang relevan dalam data melalui lapisan konvolusi dan menyederhanakan dimensi data melalui *pooling*. Representasi fitur ini kemudian diubah ke dalam format sekuensial untuk diproses oleh BiGRU. Pada tahap berikutnya, BiGRU mengolah informasi tersebut dalam dua arah, sehingga pola yang melampaui jangkauan lokal dapat diidentifikasi dengan lebih akurat. Pendekatan ini telah terbukti memberikan hasil yang unggul di berbagai bidang. Dalam pemrosesan citra spektral, kombinasi CNN dan BiGRU menghasilkan ketepatan prediksi yang tinggi dengan kesalahan yang lebih rendah. Dalam peramalan beban listrik jangka pendek dan estimasi kondisi kesehatan baterai, sinergi ini memperlihatkan kemampuan untuk meningkatkan akurasi sekaligus efisiensi komputasi. Model ini juga telah digunakan dalam prediksi harga saham, di mana pola lokal yang ditangkap CNN diperkaya dengan hubungan temporal yang dipetakan BiGRU.

Penggunaan CNN-BiGRU juga memberikan manfaat di bidang kelautan, seperti pada prediksi kondisi kabel bawah laut. CNN mampu mengisolasi ciri spasial dari data sensor, sementara BiGRU memanfaatkan informasi tersebut untuk memahami perubahan yang terjadi dalam

rentang waktu tertentu. Dalam pengenalan emosi berbasis sinyal EEG multikanal, kombinasi ini membantu mengenali pola fisiologis yang bergantung pada interaksi antara ciri lokal dan urutan temporal. Keberhasilan CNN-BiGRU terletak pada kemampuannya menggabungkan keunggulan pengolahan spasial lokal dengan pemetaan temporal global. CNN fokus mengidentifikasi pola dasar yang stabil terhadap pergeseran, sedangkan BiGRU memperkaya informasi tersebut melalui pemrosesan dua arah. Aliran fitur yang terstruktur ini memungkinkan model untuk mempelajari hubungan yang kompleks dalam data secara menyeluruh, menjadikannya andal di berbagai situasi dan jenis data.



Gambar 11. Diagram Alur Pemrosesan Data Menggunakan CNN, BiGRU, dan Self-Attention

Gambar ini memperlihatkan arsitektur gabungan yang memanfaatkan tiga komponen utama: *Convolutional Neural Network* (CNN), *Bidirectional Gated Recurrent Unit* (BiGRU), dan mekanisme *self-attention*. Alur ini dirancang untuk memaksimalkan pemahaman pola spasial dan temporal sekaligus memberikan fokus adaptif pada bagian

informasi yang paling relevan. Bagian **A** menunjukkan alur utama pemrosesan data. Proses dimulai dari data input yang dalam ilustrasi ini direpresentasikan menggunakan matriks *BLOSUM62*. Matriks ini mengubah simbol atau elemen urutan menjadi representasi numerik yang merefleksikan kemiripan atau hubungan antar elemen. Representasi ini kemudian menjadi masukan bagi lapisan CNN.

Pada tahap CNN, data melewati filter konvolusi yang bertugas mengekstrak pola lokal dari input. Setiap filter memindai representasi masukan untuk mendeteksi fitur spesifik yang signifikan. Hasil dari proses ini berupa peta fitur (*feature maps*) yang telah mengenkapsulasi informasi spasial penting dari data mentah. Lapisan CNN berfungsi sebagai tahap awal untuk mereduksi noise dan menyoroti pola yang bermanfaat sebelum diteruskan ke modul berikutnya. Hasil keluaran CNN kemudian dikirim ke *Bidirectional GRU*. Di sini, arsitektur dua arah memproses data dalam urutan maju dan mundur. Jalur maju membaca data dari awal hingga akhir, sementara jalur mundur membaca dari akhir ke awal. Pendekatan ini memastikan bahwa setiap posisi dalam urutan memiliki akses ke informasi yang berada di kedua sisinya. Output dari masing-masing arah berupa vektor representasi yang kemudian digabungkan (*concatenation*) menjadi satu vektor yang lebih kaya secara konteks.

Setelah BiGRU, representasi hasil gabungan diarahkan ke blok *self-attention*. Mekanisme ini bertugas menilai tingkat kepentingan tiap bagian dari urutan terhadap bagian lainnya. Secara intuitif, *self-attention* memberikan bobot lebih pada segmen data yang paling relevan untuk tujuan akhir model, dan mengurangi pengaruh bagian yang kurang penting. Blok ini berperan penting dalam mengarahkan fokus pemodelan,

sehingga dapat meningkatkan akurasi dan efisiensi pemrosesan. Bagian **B** pada gambar memberikan ilustrasi internal dari mekanisme *self-attention*. Tahap ini dimulai dengan input yang diubah menjadi tiga representasi: *query* (Q), *key* (K), dan *value* (V) melalui lapisan linear terpisah. *Query* dan *key* digunakan untuk menghitung tingkat kesamaan atau hubungan antara bagian yang berbeda dari urutan. Hasil perhitungan ini diolah menggunakan fungsi *softmax* untuk menghasilkan bobot perhatian (*attention weights*). Bobot ini kemudian digunakan untuk menggabungkan *value* menjadi output akhir yang merefleksikan kontribusi terpenting dari tiap bagian input. Seluruh alur dari bagian A hingga B menggambarkan bagaimana data mentah dapat diubah menjadi representasi yang sangat terstruktur dan informatif. Dimulai dari transformasi awal ke bentuk numerik, diikuti ekstraksi pola lokal oleh CNN, pemahaman konteks sekuensial dua arah oleh BiGRU, dan akhirnya penyaringan adaptif menggunakan *self-attention*. Kombinasi ini memberikan keuntungan ganda: kekuatan CNN dalam menangkap fitur spasial dan kekuatan BiGRU dalam menangkap dependensi temporal, yang kemudian diperkaya oleh kemampuan *self-attention* untuk fokus pada informasi paling relevan. Kelebihan arsitektur ini antara lain:

1. **Kemampuan Ekstraksi Multi-Tahap**

CNN mengekstrak pola lokal, BiGRU menangani urutan panjang, dan *self-attention* memastikan fokus selektif.

2. **Pemahaman Konteks Luas**

BiGRU dua arah memastikan informasi dari masa lalu dan masa depan tersedia untuk setiap titik dalam urutan.

3. **Efisiensi Pemrosesan**

Meskipun kompleks, GRU cenderung lebih ringan dibandingkan arsitektur LSTM, sehingga proses lebih cepat tanpa mengorbankan banyak akurasi.

4. **Fleksibilitas**

Setiap modul dapat disesuaikan atau diperluas, misalnya mengganti CNN dengan varian yang lebih dalam atau menambahkan lapisan *multi-head attention*.

Arsitektur seperti ini dapat diaplikasikan pada berbagai bidang, termasuk pengenalan pola pada data biologis, pemrosesan bahasa alami, pengenalan ucapan, hingga prediksi deret waktu. Dalam setiap kasus, prinsip yang sama berlaku: menggabungkan kekuatan analisis lokal dan global dengan pengaturan fokus yang cerdas akan menghasilkan model yang lebih tangguh dan akurat. Jika diibaratkan seperti proses membaca, CNN berperan sebagai pembaca yang memindai kata per kata untuk mencari bentuk atau pola tertentu. BiGRU berperan sebagai pengingat cerita yang memahami makna kalimat berdasarkan urutan kata dari awal sampai akhir dan sebaliknya. *Self-attention* adalah pembaca kritis yang memutuskan paragraf mana yang paling relevan untuk menjawab pertanyaan atau mencapai tujuan bacaan. Dengan perpaduan ini, model dapat memahami data dengan kedalaman dan ketepatan yang sulit dicapai jika hanya mengandalkan satu teknik saja.

Implementasi untuk data pasar saham multivariabel

Data pasar saham multivariable umumnya disusun dalam bentuk matriks *time series*, di mana setiap baris mewakili cuplikan waktu tertentu, seperti harian atau per menit, dan setiap kolom berisi variabel

yang relevan, meliputi harga pembukaan, harga tertinggi, harga terendah, harga penutupan, volume transaksi, serta indikator teknikal turunan. Penyusunan ini memungkinkan model *deep learning* mengakses berbagai sinyal yang saling berkaitan secara bersamaan, sehingga mendukung deteksi keterkaitan kompleks antarvariabel yang mempengaruhi pergerakan pasar. Agar informasi ini dapat dimanfaatkan secara optimal, data sering dinormalisasi dan disusun menjadi masukan multikanal. Setiap variabel diperlakukan sebagai kanal tersendiri, mirip dengan kanal warna pada citra digital. Pendekatan ini memberi lapisan konvolusi kemampuan untuk memproses setiap variabel sebagai saluran informasi terpisah sekaligus mengintegrasikan pola lintas kanal yang penting. Dengan demikian, hubungan antara harga, volume, dan indikator teknikal dapat diidentifikasi secara lebih menyeluruh.

Pengelolaan data multivariable menghadirkan sejumlah tantangan. Korelasi tinggi antarvariabel dapat memunculkan redundansi (*multicollinearity*) yang meningkatkan risiko *overfitting*. Fluktuasi tajam dan *noise* pada data memperberat proses pembelajaran. Selain itu, perbedaan skala, sifat data yang tidak stasioner, dan keberadaan nilai hilang mengharuskan penerapan pra-pemrosesan yang tepat, seperti normalisasi, pemilihan fitur yang relevan, dan reduksi dimensi. Langkah-langkah ini penting untuk memastikan hanya informasi bernilai yang masuk ke tahap pemodelan. Arsitektur *hybrid* yang menggabungkan *Convolutional Neural Networks* (CNN) dengan *Bidirectional Gated Recurrent Units* (BiGRU) menjadi solusi efektif untuk memproses data seperti ini. CNN unggul dalam menangkap korelasi lokal dan interaksi antar kanal melalui filter konvolusi yang mampu mengekstraksi ciri spasial kompleks serta mendeteksi pola yang terjadi secara bersamaan di

berbagai variabel. Setelah tahap ini, BiGRU memproses urutan *feature maps* secara dua arah untuk menggabungkan informasi dari masa lalu dan masa depan, membentuk representasi temporal yang lebih utuh.

Pendekatan berlapis ini menciptakan sinergi yang kuat. CNN menyederhanakan data dengan mengekstraksi pola lokal yang penting dan mengurangi redundansi, sementara BiGRU memperkaya hasil ekstraksi tersebut dengan menambahkan perspektif temporal dua arah. Kombinasi ini memungkinkan model untuk mengenali perubahan jangka pendek sekaligus mengidentifikasi tren jangka panjang yang esensial dalam prediksi pasar. Penerapan CNN-BiGRU pada data pasar saham multivariable terbukti meningkatkan akurasi prediksi serta ketahanan terhadap *noise*. CNN menyaring informasi lokal yang relevan, sedangkan BiGRU memastikan keterkaitan temporal tetap terjaga. Hasilnya adalah model yang mampu merepresentasikan hubungan kompleks antarindikator pasar dengan lebih presisi, mendukung proses pengambilan keputusan yang berbasis data.

Kelebihan lain dari integrasi ini adalah kemampuannya mengakomodasi sifat heterogen dari data pasar saham. CNN dapat menyesuaikan filter untuk mengungkap pola unik dari setiap kanal, sementara BiGRU menghubungkan pola-pola tersebut dalam urutan waktu yang logis. Pendekatan ini tidak hanya mendukung prediksi harga yang lebih akurat, tetapi juga memperkuat kemampuan untuk memperkirakan risiko, mendeteksi sinyal peringatan dini, dan mengidentifikasi anomali yang dapat memengaruhi pasar. Dengan rancangan masukan yang memperhitungkan keterkaitan antar kanal serta pemanfaatan arsitektur *hybrid* yang tepat, data pasar saham multivariable dapat diolah secara lebih efektif. Hasil akhirnya adalah

prediksi yang lebih tepat, pemahaman yang mendalam terhadap dinamika pasar, dan kemampuan adaptasi yang lebih baik terhadap perubahan kondisi yang cepat.

Tabel 8. Contoh Bentuk Masukan Multikanal untuk Pemodelan *Time Series*

No	Contoh Aplikasi	Format Masukan Multikanal	Deskripsi Teknis
1	Pemantauan Lingkungan dengan IoT	[batch, kanal, panjang waktu]	Setiap kanal mewakili variabel lingkungan berbeda seperti suhu, kelembapan, tekanan udara, atau kecepatan angin.
2	Klasifikasi Aktivitas Manusia	[kanal, waktu] dari sensor tubuh	Data diambil dari berbagai sensor seperti akselerometer dan giroskop yang dipasang di beberapa bagian tubuh.
3	Pemodelan Panel Data Multiseri	[instance, kanal, panjang]	Setiap <i>instance</i> mewakili subjek berbeda (misalnya mesin atau kendaraan), dan setiap kanal adalah fitur unik.
4	Prediksi Keuangan Multivariabel	[batch, panjang waktu, fitur]	Data harga, volume perdagangan, dan indikator teknikal diproses sebagai kanal berbeda dalam periode waktu tertentu.
5	Model CNN–LSTM untuk Multikanal	(None, panjang, fitur)	CNN memproses dimensi fitur untuk menangkap pola lokal sebelum LSTM memodelkan hubungan jangka panjang antar waktu.

Pemodelan *time series* modern kerap melibatkan data dari beragam sumber atau fitur yang berjalan secara paralel. Pendekatan ini dikenal sebagai *multichannel input* atau masukan multikanal. Setiap kanal merepresentasikan satu jenis informasi yang berbeda, direkam secara bersamaan, sehingga model mampu menggabungkan dan

membandingkan sinyal tersebut untuk menghasilkan prediksi maupun klasifikasi yang lebih akurat.

1. Pemantauan Lingkungan dengan *IoT*

Dalam sistem pemantauan berbasis *Internet of Things*, berbagai sensor mengukur variabel lingkungan secara bersamaan. Misalnya, stasiun cuaca otomatis dapat mencatat suhu, kelembapan, tekanan udara, dan kecepatan angin dalam periode yang sama. Format [batch, kanal, panjang waktu] memisahkan data menjadi kelompok batch (misalnya lokasi pemantauan), kanal (jenis sensor), dan panjang waktu (jumlah titik observasi). Struktur ini memudahkan model untuk memahami keterkaitan antar variabel pada setiap waktu serta hubungan temporalnya.

2. Klasifikasi Aktivitas Manusia

Masukan multikanal juga berperan penting pada pengenalan aktivitas manusia melalui sensor *wearable*. Format [kanal, waktu] di sini menggambarkan kanal yang berasal dari sensor berbeda—misalnya akselerometer pada pergelangan tangan, giroskop pada pinggang, dan sensor tekanan pada alas kaki. Masing-masing sensor memberi sudut pandang unik terhadap gerakan, dan kombinasi kanal-kanal ini memudahkan model membedakan aktivitas seperti berjalan, berlari, atau duduk.

3. Pemodelan Panel Data Multiseri

Panel data multiseri mencakup pengamatan banyak entitas dalam periode yang sama. Format [instance, kanal, panjang] membuat setiap *instance* (misalnya mesin di pabrik atau kendaraan dalam armada) memiliki deret waktunya masing-masing. Kanal di sini bisa berupa suhu mesin, getaran, konsumsi bahan bakar, atau

tekanan oli. Struktur ini memungkinkan pengenalan pola temporal tiap entitas sekaligus perbandingan antar entitas.

4. Prediksi Keuangan Multivariabel

Pasar keuangan menghasilkan data multidimensi, seperti harga penutupan, harga pembukaan, volume perdagangan, serta indikator teknikal seperti *Moving Average* dan *Relative Strength Index*. Format [batch, panjang waktu, fitur] digunakan agar setiap variabel menjadi kanal terpisah. Pendekatan ini membantu model memahami keterkaitan antar indikator, misalnya hubungan antara lonjakan volume dan perubahan harga, atau prediksi pembalikan tren.

5. Model CNN–LSTM untuk Multikanal

Integrasi CNN dan LSTM dalam pemrosesan multikanal menggunakan format (None, panjang, fitur). CNN menangkap pola spasial antar fitur pada setiap langkah waktu, sedangkan LSTM memodelkan hubungan jangka panjang di sepanjang urutan. Strategi ini banyak diterapkan pada sinyal medis multikanal seperti *Electrocardiogram* dengan banyak *lead*, data audio multimikrofon, atau data sensor gabungan pada sistem robotik.

Manfaat dan Tantangan Masukan Multikanal

Masukan multikanal memberi keunggulan dalam menangkap informasi lebih kaya dibanding data satu kanal. Dengan memanfaatkan berbagai sumber, model dapat membentuk representasi yang lebih utuh terhadap fenomena, meningkatkan akurasi, mempercepat konvergensi, dan lebih tangguh terhadap gangguan (*noise*) di salah satu kanal. Namun, peningkatan jumlah kanal juga menambah dimensi data, yang dapat


meningkatkan beban komputasi dan risiko *overfitting*. Sinkronisasi antar kanal menjadi faktor penting; perbedaan waktu pencatatan atau hilangnya data dapat memengaruhi kinerja. Normalisasi, interpolasi, dan *data augmentation* sering digunakan untuk menjaga konsistensi.

Hubungan Bentuk Input dan Arsitektur Model

Format input ditentukan oleh karakteristik data dan arsitektur model yang dipakai. CNN memerlukan format yang mendukung konvolusi pada dimensi fitur atau waktu, sementara LSTM atau GRU memerlukan urutan temporal yang rapi. Model hybrid seperti CNN–RNN membutuhkan format yang memfasilitasi kedua proses tersebut.

Aplikasi Lintas Domain

Masukan multikanal telah diadopsi di berbagai bidang. Dalam kesehatan, sinyal *ECG* multilead membantu mendeteksi gangguan jantung. Dalam otomotif, kombinasi data sensor mesin, pengereman, dan kontrol stabilitas digunakan untuk prediksi perawatan. Di pertanian cerdas, sensor kelembapan tanah, suhu udara, dan intensitas cahaya dimanfaatkan untuk mengoptimalkan irigasi. Bahkan dalam eksplorasi luar angkasa, instrumen satelit menggabungkan kanal data untuk memantau antariksa.



Gambar 12. Representasi *Multi-Channel Input* pada Harga Saham

Gambar ini menampilkan alur pengolahan data harga saham dengan pendekatan *multi-channel* yang memanfaatkan tiga jenis jaringan saraf, yaitu *Convolutional Neural Network (CNN)*, *Long Short-Term Memory (LSTM)*, dan *Recurrent Neural Network (RNN)*. Masing-masing jaringan digunakan untuk menggali keunggulan berbeda, sehingga informasi yang terkandung dalam data deret waktu harga saham dapat diproses dengan lebih mendalam dan terstruktur. Proses diawali dari sumber data yang berisi catatan historis harga saham. Data ini mencakup berbagai parameter seperti harga pembukaan (*open*), harga tertinggi (*high*), harga terendah (*low*), harga penutupan (*close*), serta volume

transaksi. Sebelum masuk ke tahap pemodelan, dilakukan *pre-processing* untuk membersihkan data, menormalkan nilai, dan mengubahnya ke dalam format yang kompatibel dengan pemrosesan model.

Data yang telah disiapkan dibagi menjadi tiga jalur pemrosesan paralel. Jalur pertama melalui *CNN*, dimulai dari *convolution layer* yang mengekstraksi pola lokal pada data *multi-channel*. Proses ini dapat mengungkap keterkaitan antar fitur harga, misalnya hubungan antara pergerakan harga penutupan dengan perubahan volume. Setelah itu, *pooling layer* digunakan untuk mereduksi dimensi data sambil mempertahankan informasi penting, kemudian dilanjutkan dengan tahap *flatten* untuk mengubah hasil ekstraksi menjadi vektor satu dimensi. Jalur kedua adalah *LSTM*, yang dirancang untuk mengelola hubungan jangka panjang dalam deret waktu. Melalui mekanisme gerbang internal, *LSTM* dapat memilih informasi yang dipertahankan atau diabaikan, sehingga mampu mengenali tren harga yang berkembang dalam periode yang lebih panjang.

Jalur ketiga memanfaatkan *RNN* standar, yang bekerja memproses data secara berurutan. Meskipun lebih sederhana dibanding *LSTM*, *RNN* tetap efektif untuk mengidentifikasi pola jangka pendek dan dinamika harga yang cepat berubah. Ketiga jalur ini menghasilkan keluaran masing-masing, yang kemudian digabung melalui blok *selection method*. Bagian ini bertugas memilih atau menggabungkan keluaran terbaik, misalnya melalui *weighted combination* atau strategi penggabungan lain, sehingga hasil akhirnya memiliki kualitas prediksi yang lebih tinggi. Tahap akhir menghasilkan *output* yang dapat berupa prediksi harga masa depan, sinyal beli atau jual, atau pengelompokan tren pasar. Dengan menggabungkan kekuatan *CNN* dalam mendeteksi pola spasial, *LSTM*

dalam memahami hubungan jangka panjang, serta *RNN* dalam menangkap pola temporal cepat, sistem ini mampu membangun model prediksi yang lebih adaptif dan andal.

Pendekatan *multi-channel* juga memastikan bahwa setiap variabel harga diproses sebagai saluran yang saling berhubungan. Hal ini memungkinkan pemahaman yang lebih baik terhadap interaksi antar variabel, misalnya pengaruh volume transaksi terhadap volatilitas atau kaitan harga tertinggi terhadap potensi perubahan tren. Arsitektur ini berpotensi diaplikasikan pada berbagai kebutuhan praktis, termasuk sistem perdagangan otomatis (*automated trading systems*), evaluasi risiko investasi, dan pengembangan strategi pasar. Dengan penyesuaian tertentu, sistem ini juga dapat bekerja pada data *real-time*, memberikan sinyal yang cepat dan relevan bagi pengambil keputusan. Integrasi dengan *attention mechanism* atau teknik penggabungan fitur lanjutan dapat semakin memperkuat kinerjanya, terutama pada kondisi pasar yang dinamis. Dengan menggabungkan ekstraksi fitur spasial, pemrosesan informasi jangka panjang, dan pengenalan pola jangka pendek, arsitektur ini menjadi pendekatan yang selaras untuk memproses data harga saham berbasis *multi-channel* yang kompleks dan bervariasi.

Bab 5. Penerapan Mekanisme Attention Model Hibrid

Prinsip kerja attention mechanism

Mekanisme *attention* merupakan salah satu inovasi yang secara signifikan meningkatkan kemampuan model *deep learning* dalam memproses data yang kompleks, khususnya pada data deret waktu multivariable seperti pasar saham. Prinsip kerjanya berfokus pada pemberian bobot dinamis terhadap bagian informasi yang dianggap paling relevan bagi tugas tertentu. Dengan kata lain, *attention* membantu model untuk "memperhatikan" sinyal-sinyal yang memiliki kontribusi besar terhadap keluaran, sekaligus mengabaikan bagian yang kurang bermakna. Pendekatan ini meningkatkan efisiensi pemrosesan sekaligus memperkaya kualitas prediksi. Dalam skema tradisional, setiap elemen dalam urutan data diproses dengan bobot yang relatif sama. Hal ini berpotensi menyebabkan model kurang peka terhadap elemen-elemen penting yang berdampak besar terhadap hasil akhir. Mekanisme *attention* mengatasi keterbatasan ini dengan menghitung skor relevansi untuk setiap bagian data. Skor ini kemudian diubah menjadi bobot yang menentukan seberapa besar kontribusi elemen tersebut terhadap representasi akhir. Dengan demikian, *attention* bertindak sebagai pengatur fokus yang adaptif dan dinamis.

Penerapan *attention* dalam arsitektur *hybrid* seperti CNN-BiGRU sangat relevan untuk data pasar saham multivariable. Data jenis ini biasanya disusun dalam bentuk matriks *time series*, di mana setiap baris merepresentasikan satu titik waktu dan setiap kolom menyimpan variabel

seperti harga pembukaan, harga tertinggi, harga terendah, harga penutupan, volume perdagangan, serta indikator teknikal. Keterkaitan antarvariabel dalam bentuk ini sering kali kompleks dan tidak linier. Mekanisme *attention* memungkinkan model untuk menyoroti hubungan-hubungan penting tersebut dengan memberikan bobot yang lebih besar pada kombinasi variabel dan waktu yang relevan. Tahap awal pemrosesan data biasanya melibatkan CNN untuk mengekstraksi fitur-fitur lokal dari masukan multikanal. CNN bekerja dengan memindai data melalui filter konvolusi yang mengidentifikasi pola-pola spasial dan interaksi antarvariabel. Hasil ekstraksi ini berbentuk *feature maps* yang telah merangkum informasi penting sekaligus mengurangi *noise*. Selanjutnya, BiGRU memproses *feature maps* tersebut secara dua arah, memungkinkan model menangkap ketergantungan temporal dari masa lalu maupun masa depan.


Mekanisme *attention* kemudian diintegrasikan setelah tahap pemodelan urutan oleh BiGRU. Pada fase ini, *attention* menghitung tingkat kepentingan setiap langkah waktu dalam urutan berdasarkan keterkaitannya dengan tujuan prediksi. Misalnya, dalam memprediksi pergerakan harga saham, *attention* dapat memberikan bobot lebih pada periode waktu tertentu ketika terjadi lonjakan volume perdagangan atau pergerakan harga yang signifikan. Proses ini membantu model menyaring informasi relevan yang tersebar di berbagai titik waktu. Manfaat utama dari penerapan *attention* adalah kemampuannya untuk menangani data dengan hubungan jangka panjang yang rumit tanpa kehilangan fokus pada elemen penting. Ini sangat bermanfaat dalam pasar saham, di mana sinyal yang mempengaruhi harga tidak selalu berada di titik waktu yang berdekatan. Dengan memprioritaskan informasi penting, *attention* juga

dapat mengurangi risiko *overfitting* karena model tidak terjebak mempelajari pola yang kurang relevan.

Selain meningkatkan akurasi prediksi, *attention* juga memberikan interpretabilitas yang lebih baik terhadap hasil model. Bobot yang dihasilkan oleh mekanisme ini dapat divisualisasikan untuk menunjukkan periode atau variabel mana yang paling mempengaruhi keputusan model. Hal ini sangat berguna bagi analis dan pengambil keputusan, karena memungkinkan verifikasi apakah model "memperhatikan" faktor-faktor yang masuk akal secara ekonomi. Integrasi *attention* dalam CNN-BiGRU juga membantu mengatasi tantangan khas data multivariable, seperti multikolinearitas dan heterogenitas skala data. Dengan memberikan bobot yang berbeda pada variabel-variabel tertentu di waktu tertentu, *attention* dapat menurunkan efek redundansi antarvariabel. Sebagai contoh, jika dua indikator teknikal memberikan informasi yang serupa, mekanisme ini dapat menyeimbangkan kontribusinya sehingga tidak terjadi pembobotan berlebihan.

Penerapan mekanisme *attention* juga sejalan dengan tren pengembangan model adaptif yang mampu beroperasi pada lingkungan pasar yang dinamis. Pasar saham bersifat fluktuatif dan sering kali dipengaruhi oleh faktor eksternal seperti berita ekonomi, kebijakan pemerintah, atau gejolak geopolitik. Dalam kondisi seperti ini, model yang mampu menyesuaikan fokusnya terhadap sinyal-sinyal baru memiliki peluang lebih besar untuk mempertahankan kinerja yang baik. Secara praktis, arsitektur CNN-BiGRU dengan *attention* dapat diimplementasikan melalui beberapa langkah kunci. Pertama, data dipra-proses untuk mengatasi perbedaan skala, *noise*, dan nilai hilang. Kedua, CNN digunakan untuk mengekstraksi pola lokal lintas kanal. Ketiga, BiGRU

memodelkan hubungan temporal dua arah. Terakhir, *attention* diterapkan untuk memberikan bobot pada elemen-elemen urutan yang paling relevan bagi prediksi. Kombinasi ini menciptakan alur kerja yang terstruktur, di mana setiap komponen memiliki peran yang jelas dan saling mendukung. Berdasarkan berbagai hasil uji, integrasi *attention* ke dalam model *hybrid* terbukti mampu meningkatkan akurasi prediksi harga saham dan estimasi risiko. Model ini tidak hanya memanfaatkan kekuatan CNN dalam menangkap pola spasial dan BiGRU dalam memahami urutan temporal, tetapi juga memanfaatkan keunggulan *attention* dalam mengarahkan fokus pemodelan. Dengan demikian, *attention* berperan sebagai lapisan tambahan yang mengoptimalkan sinergi antara ekstraksi fitur dan pemodelan urutan.



Gambar 13. Query Key Value dalam Mekanisme Attention pada Data Time Series

Gambar ini menampilkan alur kerja mekanisme *attention* berbasis *Query-Key-Value* (QKV) yang sering digunakan pada model *deep learning* untuk memproses data berurutan, termasuk *time series*.

Pendekatan ini memfasilitasi proses pemilihan informasi paling relevan dari sekumpulan data, sehingga model dapat fokus pada bagian yang memiliki pengaruh terbesar terhadap hasil akhir. Proses dimulai dari *query*, yang berperan sebagai titik acuan atau elemen yang sedang dievaluasi. *Query* ini dibandingkan dengan sejumlah *key*, masing-masing merepresentasikan elemen lain dalam urutan data. Hasil perbandingan tersebut menghasilkan nilai yang mencerminkan tingkat keterkaitan antara *query* dan setiap *key*. Dalam ilustrasi, perbandingan ini menghasilkan serangkaian skor awal (s_1, s_2, s_3, s_4) yang mengindikasikan relevansi setiap pasangan.

Skor tersebut kemudian masuk ke tahap normalisasi menggunakan *SoftMax*, yang mengubahnya menjadi bobot terukur. Bobot ini menentukan proporsi kontribusi masing-masing *key* terhadap *query*. Bobot hasil normalisasi (a_1 hingga a_4) menunjukkan sejauh mana setiap elemen akan mempengaruhi hasil akhir. Langkah berikutnya adalah penerapan bobot tersebut pada *value* yang sesuai. *Value* memuat informasi yang akan disaring dan digabungkan, misalnya representasi fitur harga saham pada waktu tertentu dalam kasus *time series*. Dengan mengalikan bobot dengan *value*, hanya informasi yang relevan yang dipertahankan, sementara yang kurang penting memiliki pengaruh lebih kecil. Hasil penggabungan ini menghasilkan *attention value*, yakni representasi informasi yang telah diseleksi berdasarkan relevansi tertinggi terhadap *query*. Nilai ini menjadi inti keluaran dari proses *attention* dan berfungsi sebagai masukan yang kaya informasi untuk tahap pemrosesan selanjutnya.

Penerapan mekanisme ini pada *time series* memungkinkan model untuk menyesuaikan fokus secara adaptif. Sebagai contoh, dalam

memprediksi pergerakan harga saham, bobot perhatian mungkin akan lebih besar pada periode dengan volatilitas tinggi atau peristiwa signifikan, dibandingkan periode dengan perubahan kecil. Dengan demikian, model dapat mengutamakan data yang memiliki potensi dampak paling besar terhadap prediksi. Gambar ini juga memperlihatkan alur informasi yang runtut, dimulai dari penerimaan *query*, penilaian relevansi terhadap setiap *key*, normalisasi bobot, penerapan bobot pada *value*, hingga pembentukan *attention value*. Proses ini memadukan pemilihan dan penggabungan informasi menjadi satu kesatuan yang lebih fokus.

Keunggulan utama dari pendekatan ini terletak pada kemampuannya menghubungkan elemen yang terpisah jarak dalam urutan waktu, baik jarak pendek maupun jauh. Berbeda dari pemrosesan berurutan tradisional yang memerlukan langkah demi langkah untuk menjangkau data lama, *attention* dapat langsung menghubungkan informasi dari dua titik waktu yang berjauhan tetapi relevan. Hal ini sangat bermanfaat untuk data yang bersifat musiman, memiliki fluktuasi acak, atau dipengaruhi kejadian tertentu yang tidak berulang secara teratur. Pendekatan *QKV attention* dapat digunakan di berbagai bidang. Di sektor keuangan, selain untuk prediksi harga saham, teknik ini dapat membantu pengelolaan risiko dan identifikasi anomali perdagangan. Dalam sektor energi, dapat digunakan untuk perkiraan beban harian atau pemantauan sistem distribusi. Di bidang kesehatan, dapat dimanfaatkan untuk mendeteksi perubahan signifikan pada sinyal vital pasien.

Mekanisme ini juga dapat dipadukan dengan arsitektur lain seperti *Convolutional Neural Network (CNN)* untuk mengekstraksi pola lokal dari *time series* multi-channel sebelum dilakukan seleksi relevansi oleh

attention. Jika digabungkan dengan *Bidirectional RNN* atau *GRU*, mekanisme ini dapat memanfaatkan informasi dari kedua arah waktu, memberikan pemahaman yang lebih menyeluruh. Dalam implementasi tingkat lanjut, mekanisme ini sering diperluas menjadi *multi-head attention*. Dengan menggunakan beberapa set *query*, *key*, dan *value* secara paralel, model dapat menangkap berbagai jenis hubungan dalam data sekaligus. Hasil dari masing-masing *head* kemudian digabungkan untuk membentuk representasi yang lebih kaya dan mendalam.

Ilustrasi ini menegaskan bahwa *attention* bukan sekadar proses seleksi informasi, tetapi juga proses penyeimbangan kontribusi setiap elemen terhadap hasil akhir. Setiap *key* memiliki peluang untuk memberikan pengaruh, namun besar kecilnya pengaruh tersebut diatur secara adaptif berdasarkan relevansinya terhadap *query*. Dengan pendekatan ini, *QKV attention* menjadi salah satu komponen penting untuk memperkuat kualitas representasi dalam model *deep learning*, terutama saat menangani *time series* yang kompleks dan dinamis. Kemampuannya memfokuskan perhatian pada bagian data yang benar-benar signifikan membuat prediksi dan pengambilan keputusan menjadi lebih tepat dan efektif.

Penekanan pada periode dan fitur

Mekanisme *attention* dalam *deep learning* dirancang untuk memberikan penekanan yang bervariasi pada bagian-bagian informasi yang paling berpengaruh terhadap keluaran model. Pendekatan ini tidak hanya fokus pada setiap langkah waktu secara seragam, tetapi secara dinamis menyesuaikan bobot berdasarkan relevansi setiap periode dan

fitur terhadap hasil prediksi. Proses ini dimulai dengan menghitung *compatibility score* antara vektor *query* yang mewakili tujuan prediksi dan *hidden state* yang mewakili setiap titik waktu dalam urutan data. Skor tersebut kemudian dinormalisasi, biasanya menggunakan fungsi *softmax*, sehingga menghasilkan bobot *attention* yang merepresentasikan tingkat kepentingan relatif tiap elemen.

Pada tingkat fitur, *attention* melakukan evaluasi kesesuaian antara vektor fitur dengan vektor *query* yang dapat dilatih. Fitur yang memiliki sinyal lebih kuat untuk mempengaruhi prediksi diberikan bobot yang lebih besar, sedangkan fitur yang kurang relevan akan tereduksi kontribusinya. Pendekatan ini sering kali diimplementasikan secara bersamaan pada dimensi waktu dan fitur, sehingga model mampu menyoroti ciri utama di titik-titik waktu yang paling kritis. *Multi-head attention* memperkaya proses ini dengan membagi evaluasi ke dalam beberapa sub-ruang representasi yang berbeda, memungkinkan model menangkap hubungan yang beragam secara paralel.

Manfaat dari penekanan ini sangat signifikan bagi pemrosesan data pasar saham multivariable. Dengan mengidentifikasi periode-periode penting—seperti saat terjadinya lonjakan harga atau perubahan volume besar—serta fitur-fitur kunci yang terkait dengannya, model dapat menyaring *noise* yang muncul dari informasi kurang relevan. Hal ini tidak hanya mengurangi risiko *overfitting* tetapi juga meningkatkan kemampuan generalisasi ke data baru. Dalam lingkungan yang dinamis seperti pasar saham, kemampuan untuk mengalihkan fokus ke sinyal yang relevan merupakan keuntungan strategis yang nyata.

Dari perspektif interpretabilitas, bobot *attention* memberikan wawasan tambahan bagi analis. Bobot ini dapat divisualisasikan dalam

bentuk *heat map* yang memperlihatkan periode dan fitur mana yang paling mempengaruhi prediksi model. Hal ini membantu menghubungkan hasil prediksi dengan fenomena pasar yang konkret, misalnya peristiwa ekonomi atau kebijakan tertentu yang memicu reaksi pasar.


Integrasi *attention* ke dalam model *hybrid* seperti CNN-BiGRU dilakukan setelah tahap ekstraksi fitur spasial oleh CNN dan pemodelan urutan temporal dua arah oleh BiGRU. CNN mengidentifikasi pola lokal lintas kanal yang mewakili harga, volume, dan indikator teknikal lainnya, sedangkan BiGRU mengaitkan pola tersebut dalam kerangka waktu yang mempertimbangkan informasi masa lalu dan masa depan. *Attention* kemudian menyaring hasil ini untuk memprioritaskan kombinasi periode dan fitur yang memiliki pengaruh paling besar terhadap keluaran akhir.

Pendekatan ini terbukti meningkatkan akurasi prediksi dan stabilitas performa model. Dalam studi pada berbagai domain, termasuk prediksi lalu lintas dan pasar finansial, model yang dilengkapi *attention* menunjukkan penurunan kesalahan prediksi dan peningkatan konsistensi hasil. Keunggulan lainnya adalah kemampuannya menyesuaikan fokus saat pola pasar berubah, misalnya ketika volatilitas meningkat atau sumber pengaruh dominan bergeser dari indikator teknikal ke faktor makroekonomi.

Secara operasional, penerapan *attention* memerlukan rancangan *pipeline* yang terstruktur. Tahapan dimulai dari pra-pemrosesan data untuk menangani perbedaan skala, menghilangkan *noise*, dan mengisi nilai yang hilang. Selanjutnya, CNN digunakan untuk memindai data dan membangun *feature maps* yang kaya informasi. BiGRU kemudian memproses representasi ini untuk membentuk pemahaman temporal

yang komprehensif. Akhirnya, *attention* mengalokasikan bobot pada periode dan fitur penting, sehingga keluaran prediksi lebih tepat sasaran.

Dalam menghadapi kompleksitas dan heterogenitas data pasar saham, mekanisme *attention* berfungsi sebagai penguat selektivitas informasi yang memperkuat sinergi antara komponen CNN dan BiGRU. Dengan kemampuannya memprioritaskan periode kritis dan ciri utama, *attention* membantu menghasilkan prediksi yang lebih akurat, adaptif, dan dapat dipertanggungjawabkan.



Gambar 14. *Heatmap Attention Weight* pada Deret Waktu

Gambar ini memperlihatkan representasi visual bobot perhatian (*attention weights*) dalam bentuk *heatmap* yang diterapkan pada pemrosesan data deret waktu (*time series*). Sumbu horizontal

menggambarkan waktu relatif pada *decoder*, sementara sumbu vertikal merepresentasikan waktu relatif pada *encoder*. Skala warna yang disajikan bergerak dari gradasi biru untuk nilai rendah hingga merah untuk nilai tinggi, mencerminkan tingkat relevansi suatu titik waktu pada *encoder* terhadap titik waktu pada *decoder*. Warna merah yang dominan pada bagian kiri atas menunjukkan area dengan bobot perhatian tinggi. Hal ini mengindikasikan bahwa pada fase tertentu *decoder* lebih memfokuskan perhatian pada informasi dari periode sebelumnya di *encoder*. Sebaliknya, area biru pada bagian bawah kanan menunjukkan bobot rendah, yang berarti periode tersebut memiliki pengaruh kecil terhadap keluaran yang dihasilkan pada titik waktu *decoder* tertentu.

Terlihat pola diagonal yang konsisten dari kiri atas menuju kanan bawah. Pola ini menggambarkan keterkaitan temporal yang kuat antara titik waktu yang berdekatan. Ketika model memproses keluaran pada suatu titik, informasi dari waktu yang hampir bersamaan atau sedikit sebelumnya cenderung menjadi sumber utama. Fenomena ini sering muncul pada data yang bersifat berkelanjutan, seperti pergerakan harga pasar, beban konsumsi energi, atau perubahan kondisi lingkungan. Visualisasi *heatmap attention* membantu dalam memahami distribusi fokus model terhadap riwayat data. Misalnya, dalam prediksi harga pasar, area merah dapat menunjukkan periode yang memiliki perubahan signifikan—baik pada harga maupun volume—yang berperan besar dalam mempengaruhi hasil prediksi. Hal ini memberi gambaran tentang titik-titik waktu yang memegang peran dominan.

Keunggulan lain dari visualisasi ini adalah kemampuannya memberikan transparansi dalam proses pengambilan keputusan. Dengan mengamati distribusi bobot, pengguna dapat menilai apakah model

memanfaatkan informasi yang masuk akal secara logis. Jika model menempatkan perhatian besar pada periode yang seharusnya tidak relevan, hal tersebut dapat menjadi indikator bahwa proses atau desain model memerlukan penyesuaian.

Heatmap attention juga memungkinkan pengamatan terhadap pola jangka pendek maupun jangka panjang. Sebaran warna merah yang meluas jauh dari diagonal menunjukkan bahwa keluaran dipengaruhi oleh informasi dari masa yang relatif jauh. Sementara fokus yang terkonsentrasi di sekitar diagonal menunjukkan ketergantungan pada hubungan jangka pendek. Fleksibilitas ini sangat penting untuk mengenali berbagai karakteristik pola dalam *time series*, baik yang stabil maupun yang dinamis. Mekanisme ini juga membantu mengatasi keterbatasan model berurutan konvensional. Arsitektur seperti RNN atau LSTM sering kesulitan mempertahankan informasi yang berasal dari waktu yang sangat jauh karena fenomena *vanishing gradient*. Dengan adanya *attention*, hubungan antar titik waktu yang berjauhan dapat dipertahankan secara langsung tanpa harus melalui seluruh rangkaian langkah di antaranya, sehingga mempermudah penangkapan pola berskala luas.

Penerapan *heatmap attention* meluas ke berbagai bidang. Di sektor energi, pola ini dapat mengungkap hubungan antara kondisi cuaca atau beban pada jam-jam tertentu dengan permintaan energi pada periode berikutnya. Dalam bidang kesehatan, *attention heatmap* dapat membantu mengenali periode kritis dalam sinyal fisiologis yang mendahului perubahan kondisi pasien. Sementara di bidang logistik, teknik ini dapat dimanfaatkan untuk memprediksi waktu kedatangan barang berdasarkan riwayat perjalanan dan kondisi transportasi.

Kombinasi *attention* dan *heatmap* juga memfasilitasi kolaborasi antara sistem dan pengambil keputusan. Representasi visual yang jelas membantu analis atau pengelola memahami alasan di balik sebuah prediksi serta menentukan tingkat kepercayaannya. Hal ini sekaligus mendukung konsep *explainable AI*, yaitu upaya menjadikan model dapat dijelaskan secara transparan kepada pengguna. Pola dalam *heatmap* dapat bervariasi bergantung pada sifat data dan tujuan pemodelan. Pada data musiman, pola merah dapat muncul secara berulang dengan interval teratur, mencerminkan siklus alami. Pada data yang dipengaruhi kejadian acak, area merah mungkin muncul secara sporadis, menandakan fokus pada momen tertentu yang jarang terjadi namun memiliki dampak besar.

Melalui pendekatan ini, interpretasi model menjadi lebih intuitif. Dengan demikian, *heatmap attention* tidak hanya menjadi peta warna yang menarik, tetapi juga jendela yang membuka wawasan tentang bagaimana model memusatkan perhatian ketika memproses data deret waktu, sehingga hasil yang dihasilkan menjadi lebih adaptif, tepat sasaran, dan relevan bagi kebutuhan praktis.

Visualisasi attention weights

Visualisasi *attention weight* menjadi salah satu langkah penting dalam memahami cara kerja model *deep learning* yang menangani data deret waktu atau data berurutan. Mekanisme ini tidak hanya memberikan bobot dinamis pada bagian data yang relevan, tetapi juga menghasilkan representasi visual yang dapat mengungkap bagian mana dari data yang paling memengaruhi keluaran model. Dengan demikian, proses ini

membantu meningkatkan keterbacaan dan interpretabilitas hasil prediksi, yang pada gilirannya memperkuat kepercayaan pengguna terhadap model. Salah satu teknik umum untuk menampilkan bobot *attention* adalah melalui *heatmap*. Dalam representasi ini, intensitas warna menunjukkan besarnya bobot yang diberikan pada setiap langkah waktu atau fitur tertentu. Warna yang lebih pekat mengindikasikan perhatian model yang lebih besar terhadap elemen tersebut. Pendekatan ini memungkinkan pengamat untuk segera mengidentifikasi periode kritis atau ciri utama yang berperan dominan dalam pembentukan prediksi. Misalnya, pada data pasar saham multivariable, *heatmap* dapat menunjukkan bahwa model memberikan perhatian lebih pada periode menjelang rilis laporan keuangan atau saat terjadi lonjakan volume perdagangan.

Selain *heatmap*, terdapat metode lain yang dapat meningkatkan keterbacaan *attention weight*, seperti *Gradient-weighted Class Activation Mapping* (Grad-CAM). Grad-CAM memanfaatkan gradien dari konsep target terhadap lapisan konvolusi terakhir untuk menghasilkan peta aktivasi yang menyoroti wilayah input yang paling relevan bagi prediksi. Teknik ini sangat bermanfaat dalam model berbasis CNN, karena dapat menghubungkan pola spasial pada input dengan keluaran model secara visual. Dalam aplikasi pasar saham, Grad-CAM dapat membantu mengidentifikasi pola harga atau volume tertentu yang menjadi fokus utama model. Untuk arsitektur berbasis *Transformer*, alat seperti BertViz memungkinkan visualisasi distribusi *attention* antar token atau elemen input. Pengguna dapat menelusuri bagaimana model mendistribusikan fokusnya pada berbagai bagian urutan, sehingga mempermudah pemahaman hubungan antar elemen yang mungkin tidak langsung


terlihat. Pendekatan ini relevan ketika model memproses berita atau teks yang berkaitan dengan pasar, di mana hubungan antar kata atau frasa dapat memengaruhi sentimen pasar.

Metode lain seperti *t-distributed Stochastic Neighbor Embedding* (t-SNE) juga dapat digunakan untuk memvisualisasikan representasi *embedding* yang dihasilkan oleh model. t-SNE memproyeksikan data berdimensi tinggi ke dalam ruang dua atau tiga dimensi, sehingga membentuk kluster yang dapat merepresentasikan kesamaan antar fitur atau periode waktu. Visualisasi ini dapat membantu menemukan pola tersembunyi yang mungkin tidak terdeteksi melalui analisis numerik semata. Manfaat dari visualisasi *attention weight* melampaui sekadar interpretasi teknis. Dengan representasi visual yang jelas, pemangku kepentingan seperti analis keuangan, manajer risiko, dan pengambil keputusan dapat memahami alasan di balik prediksi model. Hal ini sangat penting di bidang yang berisiko tinggi seperti keuangan, di mana setiap keputusan dapat berdampak besar. Visualisasi juga dapat digunakan untuk mendeteksi potensi bias atau kelemahan model. Misalnya, jika model secara konsisten memberikan bobot tinggi pada periode yang tidak relevan secara fundamental, hal tersebut dapat menjadi indikator perlunya penyesuaian atau pelatihan ulang.

Visualisasi yang efektif juga dapat meningkatkan akuntabilitas model. Dengan bukti visual mengenai bagaimana model membuat keputusan, organisasi dapat memastikan bahwa prediksi selaras dengan logika bisnis dan prinsip etika yang berlaku. Hal ini semakin relevan dalam era regulasi yang menuntut transparansi algoritmik di berbagai sektor. Dalam kerangka model *hybrid* CNN-BiGRU dengan *attention*, visualisasi bobot *attention* dapat membantu memverifikasi apakah integrasi antar

komponen bekerja sesuai tujuan. CNN bertugas menangkap pola spasial dan interaksi antar fitur, BiGRU memodelkan hubungan temporal dua arah, dan *attention* menyaring hasil ini untuk fokus pada elemen paling relevan. Visualisasi bobot *attention* dari tahap akhir memungkinkan pengembang dan pengguna memastikan bahwa model benar-benar menekankan periode serta fitur yang bermakna.

Secara operasional, penerapan visualisasi *attention weight* memerlukan pipeline yang mencakup: (1) ekstraksi bobot *attention* dari model terlatih, (2) pemetaan bobot tersebut ke fitur atau periode waktu, dan (3) penyajian visual dalam format yang intuitif seperti *heatmap*, peta aktivasi, atau proyeksi t-SNE. Proses ini dapat dilakukan menggunakan pustaka visualisasi seperti Matplotlib, Seaborn, atau alat khusus seperti BertViz untuk model berbasis *Transformer*. Dengan demikian, visualisasi *attention weight* berperan ganda: sebagai sarana interpretasi model yang memperjelas logika internalnya, dan sebagai alat evaluasi untuk memastikan keandalan prediksi. Dalam dunia pasar saham yang kompleks dan dinamis, kemampuan untuk melihat "apa yang diperhatikan model" memberikan nilai tambah yang signifikan, baik untuk validasi teknis maupun untuk pengambilan keputusan yang berbasis bukti.



Gambar 15. Heatmap Attention Weight antar Kategori Hubungan dalam Data

Gambar ini memperlihatkan representasi visual berupa *heatmap* yang menampilkan distribusi *attention weight* antara berbagai kategori hubungan yang telah ditetapkan sebelumnya. Gradasi warna berkisar dari kuning pucat hingga hijau pekat. Warna yang semakin gelap menunjukkan bobot perhatian yang lebih tinggi, sedangkan warna yang lebih terang menggambarkan bobot yang lebih rendah. Skala di sisi kanan memberikan kisaran nilai bobot, mulai dari sekitar 0,08 hingga 0,14. Sumbu horizontal dan vertikal menampilkan label yang merepresentasikan pasangan kategori, seperti *Pos. DE*, *Neg. DE*, *Wh. IN*, *Yes-no IN*, dan *A-not-A IN*. Format label menggunakan tanda pemisah “|” untuk menghubungkan dua kategori. Sebagai contoh, *Pos. DE|Pos. DE* menunjukkan hubungan antara kategori *Positive Declarative* dengan

dirinya sendiri, sedangkan *Pos. DE/Neg. DE* menggambarkan hubungan antara *Positive Declarative* dengan *Negative Declarative*.

Bagian diagonal utama dari *heatmap*, yang memanjang dari kiri atas ke kanan bawah, secara dominan berwarna lebih gelap dibandingkan area lainnya. Pola ini menandakan bahwa hubungan suatu kategori dengan dirinya sendiri mendapatkan bobot perhatian relatif tinggi. Contohnya, pasangan *Pos. DE/Pos. DE* dan *Neg. DE/Neg. DE* berada pada sel dengan warna hijau pekat, mengindikasikan keterkaitan internal yang kuat. Hal ini lazim terjadi karena elemen dalam kategori yang sama umumnya memiliki kemiripan sifat, sehingga model memberikan fokus lebih pada hubungan internal tersebut. Selain diagonal utama, terlihat pula area di luar diagonal yang menunjukkan hubungan lintas kategori. Misalnya, *Pos. DE/Neg. DE* memiliki warna yang cukup gelap, menandakan bahwa hubungan antara pernyataan positif dan negatif dianggap relevan oleh model. Keterkaitan semacam ini dapat diartikan sebagai indikasi bahwa model memanfaatkan informasi dari kategori yang bersifat kontras untuk memperkuat pemahaman. Sebaliknya, pasangan seperti *Yes-no IN/Pos. DE* atau *Wh. IN/Pos. DE* cenderung memiliki warna lebih terang, yang mengindikasikan kontribusi relatif lebih rendah.

Visualisasi ini memudahkan pengamatan preferensi model dalam memproses hubungan antar kategori. Warna hijau pekat menunjukkan relasi yang sering menjadi pusat perhatian, sedangkan warna yang lebih terang menandakan relasi yang jarang diperhatikan. Informasi ini bermanfaat untuk memahami pola interaksi yang mungkin sulit diidentifikasi hanya melalui data numerik. Pola distribusi pada *heatmap* juga menunjukkan bahwa beberapa kategori memiliki hubungan signifikan dengan lebih dari satu kategori lain. Misalnya, *Wh. IN/Neg. DE*

dan *Neg. DE/Pos. DE* menampilkan bobot yang cukup tinggi di luar diagonal, yang merefleksikan adanya interaksi lintas kategori yang kompleks. Hal ini mengindikasikan bahwa fokus model tidak semata-mata pada kesamaan kategori, tetapi juga pada kombinasi informasi dari kategori yang berbeda.

Visualisasi ini juga dapat menjadi sarana untuk meninjau kembali kinerja sistem. Apabila ditemukan bobot tinggi pada relasi yang dinilai tidak relevan, hal tersebut dapat menjadi indikasi bahwa fokus model perlu diarahkan ulang. Sebaliknya, bobot rendah pada hubungan yang semestinya penting dapat mengisyaratkan perlunya penyesuaian dalam pemrosesan data atau struktur model. Penggunaan *heatmap attention* banyak diterapkan pada sistem berbasis *attention mechanism*, termasuk dalam *natural language processing*, pemodelan *time series*, maupun pengolahan sinyal kompleks. Dalam sektor keuangan, misalnya, label kategori dapat mewakili indikator teknikal atau sentimen berita, dan *heatmap* dapat memperlihatkan keterkaitan antar indikator tersebut. Dalam bidang medis, label kategori dapat berupa jenis gejala atau hasil uji laboratorium, di mana *heatmap* dapat mengungkap hubungan yang relevan bagi diagnosis.

Penggunaan skema warna gradasi pada visualisasi ini memberikan kemudahan dalam interpretasi. Perbedaan intensitas warna membantu pengamat mengidentifikasi area penting secara cepat tanpa harus memeriksa nilai numerik secara detail. Warna hijau pekat secara alami menarik perhatian pada area dengan bobot tinggi, sementara warna kuning pucat mengarahkan pada area dengan bobot rendah. Selain fungsi teknis, *heatmap* juga berperan sebagai alat komunikasi yang efektif antara pengembang dan pihak non-teknis. Visualisasi ini mempermudah

pemahaman proses pengambilan keputusan, sehingga dapat meningkatkan transparansi dan kepercayaan terhadap sistem. Jika dikaitkan dengan penerapan praktis, pola hubungan yang ditampilkan dapat diartikan sebagai cerminan proses pembelajaran sebuah sistem. Sebagai contoh, tingginya bobot pada *Pos. DE/Neg. DE* dapat diartikan sebagai strategi pembandingan, di mana informasi positif digunakan untuk memvalidasi atau mengontraskan informasi negatif. Prinsip ini sangat berguna, misalnya, dalam deteksi opini atau analisis sentimen yang membutuhkan pemahaman nuansa antara pandangan yang berbeda.

Jenis-jenis mekanisme attention mechanisms

Mekanisme *attention* telah berkembang menjadi bagian penting dalam pemodelan data berurutan, khususnya di bidang finansial yang memiliki sifat dinamis dan penuh variasi. Kemampuannya dalam menyoroti bagian input yang paling relevan membantu meningkatkan ketepatan dan konsistensi hasil prediksi. Dua jenis *attention* yang paling menonjol adalah *self-attention* dan *additive attention*, masing-masing memiliki sifat, keunggulan, dan peran yang berbeda sesuai tujuan pemodelan serta kapasitas komputasi yang tersedia.

***Self-Attention* dan Keunggulannya**

Self-attention bekerja dengan menghitung bobot perhatian berdasarkan hubungan antar elemen dalam urutan input. Setiap posisi dalam data dapat mempertimbangkan informasi dari seluruh posisi lainnya, sehingga mampu menangkap ketergantungan jangka panjang dengan efektif. Keunggulan lain yang menonjol adalah kemampuannya

memproses data secara paralel, sehingga mempercepat perhitungan tanpa mengorbankan ketelitian. Dalam peramalan deret waktu finansial, sifat ini sangat membantu karena pola harga, volume, atau indikator lain yang relevan sering tersebar di berbagai titik waktu. Model modern seperti *Transformer*, yang mengandalkan *self-attention*, terbukti unggul dalam membaca pola kompleks antar variabel, baik hubungan langsung maupun tidak langsung. Beberapa inovasi bahkan mengoptimalkan efisiensi *self-attention* untuk menangani urutan panjang, menjadikannya semakin relevan bagi sektor keuangan yang penuh data historis.

***Additive Attention* dan Karakteristiknya**

Berbeda dari *self-attention*, *additive attention* menghitung bobot dengan memanfaatkan jaringan *feedforward* yang menerima gabungan vektor *query* dan vektor terencode sebagai input. Fokus utamanya adalah mengukur keterkaitan antara elemen input tertentu dengan *query* yang sedang diproses. Pendekatan ini lebih mengutamakan relevansi langsung antara input dan target, sehingga cocok ketika diperlukan sorotan tajam pada bagian data yang paling berpengaruh. Keunggulan *additive attention* terletak pada kemudahannya untuk diinterpretasikan. Mekanisme ini memudahkan penelusuran kontribusi setiap fitur atau periode waktu terhadap hasil akhir. Dalam dunia finansial, hal ini bermanfaat untuk memahami indikator teknikal yang memengaruhi keputusan atau menilai respons pasar terhadap peristiwa ekonomi tertentu.

Pemilihan Jenis *Attention* Berdasarkan Kebutuhan


Pemilihan jenis *attention* perlu disesuaikan dengan tujuan penggunaan dan batasan yang dimiliki. *Self-attention* sangat tepat ketika

diperlukan pemahaman interaksi global antar elemen input serta efisiensi pemrosesan secara paralel. Sementara itu, *additive attention* lebih sesuai untuk tujuan yang menuntut tingkat keterbacaan tinggi, di mana hubungan spesifik antara input dan target perlu terlihat jelas. Dalam lingkungan pasar saham yang mudah berubah, *self-attention* sering memberikan performa unggul ketika digabungkan ke dalam model *hybrid*. Kemampuannya membagi fokus secara adaptif ke seluruh elemen input membantu menangkap dinamika pasar yang kompleks, menghasilkan prediksi yang presisi dan stabil. Namun, jika tujuan utamanya adalah memberikan gambaran yang jelas bagi pengambil keputusan, *additive attention* dapat menjadi pilihan yang lebih efektif.

Integrasi dalam Model *Hybrid*

Penggabungan *attention* ke dalam arsitektur *hybrid* seperti CNN, LSTM, atau BiGRU memberikan manfaat tambahan pada data finansial yang berfluktuasi tinggi. Kombinasi *self-attention* dengan LSTM, misalnya, memanfaatkan kekuatan LSTM dalam menyimpan informasi jangka panjang dan kemampuan *attention* dalam menyoroti sinyal penting. Pendekatan ini membantu meredam *noise* serta menjaga keandalan prediksi. Sementara itu, integrasi *additive attention* dengan model sekuensial memberikan kejelasan dalam melihat kontribusi setiap fitur terhadap hasil. Hal ini memungkinkan penyesuaian strategi berdasarkan pengetahuan lapangan dan kebutuhan spesifik pengguna. Dengan memahami variasi dan peran masing-masing mekanisme, pengembangan model dapat diarahkan untuk memaksimalkan kinerja sekaligus menjaga interpretabilitas. Kedua jenis *attention* tersebut, ketika diterapkan dengan tepat dan dipadukan dengan arsitektur yang sesuai,

mampu memberikan kombinasi kekuatan yang menghasilkan prediksi lebih akurat, stabil, dan mudah dipahami di tengah dinamika pasar yang selalu berubah.



Gambar 16. Struktur Multi Head Attention

Gambar ini menampilkan arsitektur *multi-head attention*, salah satu komponen utama dalam model *transformer* dan berbagai sistem pemrosesan data modern. Mekanisme ini dirancang untuk memungkinkan model memproses informasi dari berbagai sudut pandang secara paralel, sehingga menghasilkan representasi yang lebih kaya dan menyeluruh terhadap data masukan. Struktur ini dimulai dari tiga komponen utama: *Query* (Q), *Key* (K), dan *Value* (V). Ketiganya merupakan representasi vektor yang berasal dari data masukan atau dari tahap sebelumnya dalam jaringan. Setiap komponen melewati lapisan *linear* yang berfungsi untuk mentransformasi dimensi vektor agar sesuai dengan kebutuhan proses

perhatian. Transformasi ini membantu membentuk ruang representasi yang memudahkan perhitungan kesesuaian dan relevansi antar elemen data.

Setelah proses *linear*, data dari *Query*, *Key*, dan *Value* masuk ke dalam blok *Attention*. Pada tahap ini, setiap *head* dalam multi-head attention memproses data secara independen. Masing-masing *head* memiliki parameter yang berbeda, sehingga dapat mempelajari hubungan yang beragam di antara elemen-elemen input. Misalnya, satu *head* mungkin fokus pada hubungan jarak dekat antar kata dalam teks, sedangkan *head* lain mempelajari keterkaitan yang lebih jauh atau hubungan semantik yang lebih kompleks. Jumlah *head* (dilambangkan sebagai H pada gambar) menentukan banyaknya jalur pemrosesan paralel yang bekerja secara bersamaan. Keuntungan dari pendekatan ini adalah kemampuan untuk menangkap berbagai tipe hubungan dalam satu kali proses, tanpa kehilangan fokus pada detail spesifik maupun gambaran umum. Hasil dari setiap *head* kemudian dikombinasikan melalui proses *concat* (*concatenation*). Pada tahap ini, semua representasi dari berbagai *head* digabungkan menjadi satu vektor besar. Penggabungan ini bukan sekadar menyatukan data, tetapi juga menyimpan keragaman perspektif yang telah dipelajari masing-masing *head*.

Setelah proses *concat*, vektor gabungan melewati lapisan *linear* terakhir. Lapisan ini berfungsi untuk memproyeksikan kembali vektor hasil gabungan ke dimensi yang sesuai dengan sistem, sehingga dapat diproses lebih lanjut oleh lapisan berikutnya dalam arsitektur model. Proses ini juga membantu mengintegrasikan informasi dari semua *head* menjadi satu representasi yang kohesif dan siap digunakan. Secara

keseluruhan, arsitektur *multi-head attention* memiliki peran penting dalam meningkatkan kapasitas pemodelan. Tidak seperti perhatian tunggal (*single attention*), yang mungkin hanya menangkap satu jenis hubungan, pendekatan multi-head memungkinkan model untuk mempelajari banyak hubungan sekaligus. Ini membuatnya sangat efektif dalam berbagai tugas seperti pemrosesan bahasa alami, pengenalan pola pada data deret waktu, atau bahkan pemrosesan citra.


Penggunaan mekanisme ini juga mempermudah model untuk memproses data secara efisien. Karena setiap *head* bekerja secara paralel, informasi dapat diproses dalam waktu yang relatif singkat, bahkan untuk data dengan dimensi besar. Paralelisme ini memanfaatkan kekuatan komputasi modern, seperti GPU atau TPU, untuk mempercepat proses pelatihan dan inferensi. Dalam praktiknya, *multi-head attention* juga memiliki kemampuan adaptif. Setiap *head* dapat menyesuaikan fokusnya berdasarkan jenis data dan tujuan pemrosesan. Misalnya, dalam sistem terjemahan mesin, satu *head* dapat fokus pada kesesuaian tata bahasa, sementara *head* lain lebih memperhatikan kesamaan makna. Kombinasi perspektif ini membantu menghasilkan terjemahan yang lebih akurat dan alami.

Selain di bidang bahasa, arsitektur ini telah digunakan dalam berbagai domain lain. Pada pemrosesan data deret waktu, *multi-head attention* dapat mempelajari pola musiman, tren jangka panjang, dan anomali secara bersamaan. Dalam visi komputer, teknik ini dapat digunakan untuk mengenali objek pada citra dengan memperhatikan berbagai bagian gambar sekaligus. Keunggulan lain dari *multi-head attention* adalah sifatnya yang interpretatif. Dengan memeriksa bobot perhatian yang dihasilkan masing-masing *head*, peneliti atau

pengembang dapat memahami bagian mana dari input yang dianggap penting oleh model. Ini membantu membangun sistem yang lebih transparan dan dapat dijelaskan kepada pengguna akhir (*explainable AI*). Implementasi *multi-head attention* juga dapat dikombinasikan dengan mekanisme tambahan seperti *positional encoding* untuk menangani urutan data, atau *feed-forward networks* untuk memperluas kapasitas transformasi representasi. Kombinasi ini membentuk fondasi model *transformer*, yang saat ini menjadi tulang punggung banyak teknologi AI canggih. Jika kita memerhatikan alur pada Gambar 16, prosesnya berjalan secara terstruktur:

1. Input dibagi menjadi tiga representasi terpisah (Q, K, V).
2. Masing-masing representasi diubah oleh lapisan *linear* awal.
3. Data masuk ke blok *attention*, di mana setiap *head* bekerja mandiri.
4. Hasil dari seluruh *head* digabungkan melalui *concat*.
5. Output gabungan diproyeksikan kembali ke dimensi yang sesuai melalui lapisan *linear* akhir.

Pendekatan ini menegaskan bahwa kekuatan *multi-head attention* terletak pada keberagaman perspektif yang dipelajari, serta kemampuannya mengintegrasikan semua informasi tersebut menjadi satu representasi yang padat, informatif, dan siap digunakan untuk langkah pemrosesan berikutnya. Dengan struktur yang modular dan fleksibel, *multi-head attention* dapat diadaptasi ke berbagai jenis data dan tujuan aplikasi. Fleksibilitas inilah yang membuatnya menjadi komponen esensial dalam perkembangan sistem AI modern.



Gambar 17. Spatial Attention Mechanism

Gambar ini menggambarkan alur kerja *spatial attention mechanism*, sebuah pendekatan yang digunakan untuk menekankan bagian-bagian penting dari data berdasarkan posisi atau lokasi spasialnya. Proses ini sangat berguna dalam berbagai bidang seperti pengolahan citra, pengenalan pola spasial, dan analisis sinyal, karena mampu membantu model memfokuskan sumber daya pemrosesan pada wilayah-wilayah yang paling relevan. Alur dimulai dari *input signal* yang dilabeli s pada bagian bawah diagram. Sinyal masukan ini bisa berupa citra, peta fitur hasil ekstraksi sebelumnya, atau data spasial lainnya. Tahap pertama yang dilalui adalah *convolutional layer*, yang dilengkapi dengan 16 *filters* dan ukuran *kernel*/32. Lapisan konvolusional ini bertugas mengekstraksi fitur spasial dari sinyal masukan dengan mendeteksi pola

lokal seperti tepi, tekstur, atau struktur geometris lainnya. Proses konvolusi ini menghasilkan peta fitur (*feature maps*) yang merepresentasikan informasi lokal dari setiap wilayah spasial pada input. Peta fitur hasil konvolusi kemudian diarahkan ke *global average pooling layer*. Fungsi dari lapisan ini adalah mereduksi dimensi peta fitur dengan cara menghitung nilai rata-rata dari setiap kanal. Hal ini memberikan representasi global dari seluruh informasi spasial tanpa kehilangan karakteristik utama. *Global average pooling* sering digunakan untuk mengurangi kompleksitas komputasi sambil mempertahankan informasi penting yang bersifat ringkas.

Hasil dari *global average pooling* kemudian masuk ke tahap *softmax layer*. Lapisan *softmax* ini menghasilkan bobot perhatian awal dalam bentuk vektor (a_1, a_2, a_3 , dan seterusnya). Bobot ini menunjukkan tingkat kepentingan relatif dari masing-masing kanal atau wilayah fitur yang dihasilkan oleh proses konvolusi. Nilai bobot ini dinormalisasi sehingga totalnya menjadi proporsional, memungkinkan model untuk memberikan prioritas yang jelas terhadap area tertentu. Secara paralel, peta fitur dari *convolutional layer* juga menghasilkan representasi lain yang dilabeli sebagai e_1, e_2, e_3 , dan seterusnya. Representasi ini kemudian dipasangkan dengan bobot perhatian awal ($a_1, a_2, a_3, \dots$) yang dihasilkan oleh *softmax*. Proses ini dilakukan melalui operasi perkalian elemen demi elemen (*element-wise multiplication*), yang bertujuan untuk menyesuaikan setiap representasi fitur berdasarkan tingkat perhatiannya. Dengan cara ini, fitur yang dianggap lebih penting oleh mekanisme *attention* akan diperkuat, sedangkan fitur yang kurang relevan akan diredam.

Hasil dari perkalian ini kemudian dikombinasikan dalam *point-wise sum layer*. Lapisan ini menjumlahkan setiap elemen pada posisi spasial yang sama di seluruh kanal, menghasilkan sebuah vektor perhatian akhir (*attentive vector* q). Vektor ini merepresentasikan gabungan informasi spasial yang sudah disesuaikan dengan tingkat kepentingan masing-masing wilayah. Selanjutnya, *attentive vector* ini digunakan untuk memodulasi sinyal keluaran. Modulasi ini dilakukan dengan operasi perkalian terhadap sinyal masukan atau representasi fitur tertentu untuk menghasilkan keluaran akhir (*output so*). Proses ini memastikan bahwa hanya bagian-bagian dari input yang relevan menurut mekanisme perhatian yang berkontribusi secara signifikan terhadap hasil akhir.

Menariknya, diagram ini juga memperlihatkan adanya jalur umpan balik (*feedback loop*) dari *output so* kembali ke tahap awal mekanisme perhatian. Hal ini memberi indikasi bahwa sistem ini dapat menggunakan informasi dari keluaran sebelumnya untuk memengaruhi distribusi perhatian pada langkah berikutnya. Pendekatan ini dapat meningkatkan kemampuan adaptasi sistem terhadap data yang memiliki dinamika spasial kompleks. Dari perspektif fungsional, *spatial attention mechanism* seperti ini memberikan keuntungan besar dalam pemrosesan data yang memiliki dimensi spasial signifikan. Pada pengolahan citra, misalnya, mekanisme ini dapat memfokuskan perhatian pada bagian objek yang penting seperti wajah pada gambar potret atau komponen utama pada citra medis. Dalam pengolahan sinyal spasial lainnya, mekanisme ini bisa digunakan untuk mengidentifikasi sumber bunyi dominan atau pola distribusi energi pada radar.


Proses penguatan (*amplification*) dan peredaman (*suppression*) fitur yang dilakukan oleh *spatial attention* memungkinkan model untuk

lebih efisien dalam memanfaatkan sumber daya komputasi. Alih-alih memproses semua bagian data secara merata, sistem dapat memusatkan perhatiannya pada area yang memiliki dampak terbesar terhadap tujuan akhir, seperti klasifikasi, segmentasi, atau deteksi objek. Selain itu, mekanisme ini juga berkontribusi pada peningkatan interpretabilitas sistem berbasis pembelajaran mesin. Dengan memeriksa vektor perhatian atau peta perhatian yang dihasilkan, pengguna dapat memahami bagian mana dari input yang dianggap penting oleh model. Hal ini tidak hanya membantu dalam evaluasi kualitas model, tetapi juga dalam proses perbaikan dan penyesuaian model agar sesuai dengan kebutuhan spesifik.

Penerapan *spatial attention mechanism* tidak terbatas pada domain visual saja. Dalam analisis data *time-series* dengan struktur spasial, misalnya pada data cuaca yang diambil dari berbagai titik geografis, mekanisme ini dapat memprioritaskan lokasi-lokasi yang memberikan kontribusi signifikan terhadap peristiwa yang sedang diamati, seperti badai atau gelombang panas. Di bidang biomedis, mekanisme ini dapat digunakan untuk memfokuskan analisis pada area tertentu dari citra MRI atau CT scan yang menunjukkan indikasi adanya kelainan. Struktur yang ditunjukkan pada Gambar 17 juga memberikan fleksibilitas tinggi untuk diintegrasikan dengan berbagai arsitektur jaringan lain. *Spatial attention* dapat dipadukan dengan *temporal attention* untuk membentuk mekanisme gabungan yang menangkap hubungan spasial dan temporal secara bersamaan. Hal ini sangat bermanfaat untuk data yang memiliki dimensi ruang dan waktu, seperti video atau sensor multi-lokasi yang merekam data secara berkelanjutan.

Keunggulan lain dari arsitektur ini adalah kemampuannya untuk bekerja secara *end-to-end* dalam pelatihan. Semua komponen, mulai dari *convolutional layer* hingga *point-wise sum layer*, dapat dioptimalkan secara bersamaan menggunakan algoritma pembelajaran berbasis gradien. Ini memastikan bahwa mekanisme perhatian yang terbentuk benar-benar selaras dengan tujuan akhir sistem.

Dengan memperhatikan seluruh alur yang tergambar, jelas bahwa mekanisme ini dirancang untuk menyaring informasi dengan sangat selektif. Lapisan konvolusi bertugas mengekstrak pola lokal, *global average pooling* merangkum informasi secara ringkas, *softmax layer* menetapkan bobot relevansi, perkalian elemen demi elemen menyesuaikan kekuatan fitur, dan *point-wise sum layer* menggabungkannya menjadi representasi akhir yang siap digunakan. Keseluruhan proses ini kemudian memodulasi sinyal keluaran sehingga lebih akurat dan informatif. Jika diibaratkan, *spatial attention mechanism* berfungsi seperti sorotan lampu panggung yang diarahkan pada bagian tertentu dari panggung pertunjukan. Lampu tersebut tidak menerangi semua area secara merata, tetapi memfokuskan cahaya pada aktor atau objek yang paling penting pada saat itu. Dengan cara ini, perhatian penonton diarahkan ke bagian yang relevan, sementara bagian lain tetap berada di latar belakang. Pendekatan ini mencerminkan salah satu prinsip utama dalam desain sistem cerdas: kemampuan untuk mengabaikan informasi yang tidak relevan demi meningkatkan efisiensi dan akurasi. Dengan memanfaatkan *spatial attention*, sistem dapat menyesuaikan fokusnya secara dinamis sesuai dengan karakteristik data, sehingga mampu menghadapi beragam situasi dan tantangan yang muncul dalam berbagai aplikasi nyata.



Gambar 18. Arsitektur Global Attention

Gambar ini memperlihatkan alur *arsitektur global attention*, yang dirancang untuk memberikan kemampuan kepada model dalam menentukan bagian mana dari masukan (*input*) yang harus mendapat perhatian lebih besar saat menghasilkan keluaran (*output*). Pendekatan ini memanfaatkan proses pembobotan adaptif terhadap seluruh bagian data masukan, sehingga mampu menangkap hubungan dan relevansi informasi secara menyeluruh. Alur dimulai dari bagian bawah diagram, yaitu *Input*. Data yang masuk ke sistem dapat berupa vektor fitur hasil

ekstraksi sebelumnya, sinyal terproses, atau representasi lain yang sesuai dengan tugas pemodelan. Setelah masuk, data langsung diarahkan ke *Dense Layer* pertama dengan jumlah *nodes* sebanyak 32. Lapisan ini bertugas melakukan transformasi awal terhadap data masukan, menggabungkan dan mengubah dimensi fitur agar lebih sesuai untuk tahap pemrosesan berikutnya. Transformasi ini membantu model mulai mempelajari kombinasi fitur yang lebih representatif.

Keluaran dari *Dense Layer* pertama diteruskan ke *Batch Normalization Layer*. Lapisan ini memiliki peran penting dalam menstabilkan distribusi nilai antar *batch*, sehingga proses pembelajaran menjadi lebih konsisten dan cepat. Dengan melakukan normalisasi, lapisan ini juga membantu mengurangi risiko nilai bobot yang terlalu besar atau terlalu kecil yang dapat memperlambat konvergensi pelatihan. Setelah normalisasi, data melewati *ReLU Activation Function*. Fungsi aktivasi ini berperan untuk memperkenalkan sifat non-linearitas ke dalam model, memungkinkan sistem mempelajari hubungan yang kompleks antar fitur. *ReLU* juga membantu mencegah masalah seperti *vanishing gradient*, sehingga sinyal pembelajaran tetap kuat di seluruh lapisan jaringan.

Tahap berikutnya adalah *Dense Layer* kedua dengan jumlah *nodes* sebesar ukuran masukan (*input_size*). Lapisan ini memperluas atau menyesuaikan dimensi data sesuai kebutuhan mekanisme *attention*. Tujuannya adalah mempersiapkan representasi yang dapat digunakan secara langsung untuk menghitung bobot perhatian terhadap setiap elemen masukan. Keluaran dari lapisan ini kembali dinormalisasi melalui *Batch Normalization Layer* kedua. Sama seperti sebelumnya, proses ini memastikan stabilitas nilai fitur, sehingga langkah berikutnya dapat

memanfaatkan informasi tanpa distorsi yang disebabkan oleh distribusi yang terlalu bervariasi antar *batch*.

Setelah normalisasi kedua, data memasuki *Softmax Activation Function*. Lapisan ini berfungsi untuk mengubah nilai mentah menjadi bobot perhatian (*attention weights*) yang terdistribusi secara proporsional. Nilai-nilai bobot ini akan berada pada rentang antara nol hingga satu dan jumlahnya selalu sama dengan satu. Dengan cara ini, setiap bagian dari masukan akan diberi tingkat prioritas yang sesuai, tergantung relevansinya terhadap keluaran yang diinginkan. Bobot perhatian yang dihasilkan disebut *Attention Vector*. Vektor ini merepresentasikan peta fokus model terhadap seluruh elemen masukan. Bagian masukan yang dianggap penting akan memiliki bobot lebih besar, sedangkan bagian yang kurang relevan akan diberi bobot lebih kecil. Proses ini mencerminkan konsep *global attention*, di mana semua elemen masukan dipertimbangkan secara bersamaan untuk menentukan fokus.


Tahap selanjutnya adalah menggabungkan *Attention Vector* dengan data masukan asli melalui operasi perkalian elemen demi elemen (*element-wise multiplication*). Langkah ini memastikan bahwa setiap elemen masukan diperkuat atau dilemahkan sesuai bobot perhatiannya. Elemen dengan bobot tinggi akan memberikan kontribusi lebih besar terhadap hasil akhir, sedangkan elemen dengan bobot rendah akan memiliki dampak yang minimal. Hasil dari proses penggabungan ini menjadi *Output*. Keluaran ini merepresentasikan data masukan yang telah difilter secara adaptif oleh mekanisme perhatian. Dengan demikian, *output* ini memuat informasi yang lebih fokus dan relevan terhadap tugas yang sedang dijalankan, seperti klasifikasi, prediksi, atau deteksi pola.

Menariknya, diagram ini juga menampilkan jalur umpan balik (*feedback loop*) dari *Output* kembali ke tahap awal pengolahan. Hal ini menunjukkan bahwa informasi hasil pemrosesan dapat digunakan kembali untuk mempengaruhi perhitungan perhatian pada iterasi berikutnya. Dengan adanya mekanisme ini, sistem dapat meningkatkan akurasi dan konsistensinya secara berulang berdasarkan pengalaman yang diperoleh dari hasil sebelumnya. Dari sisi fungsi, *arsitektur global attention* memiliki keunggulan dalam menangkap hubungan jangka panjang antar elemen masukan. Tidak seperti mekanisme perhatian lokal yang hanya mempertimbangkan area terbatas, *global attention* memproses semua bagian masukan sekaligus, sehingga mampu mengidentifikasi pola yang tersebar di seluruh data. Keunggulan ini sangat bermanfaat untuk data dengan dependensi panjang, seperti teks panjang, rangkaian waktu (*time-series*), atau citra dengan distribusi informasi yang merata.

Dalam praktiknya, mekanisme seperti ini dapat digunakan di berbagai bidang. Pada pengolahan bahasa alami, *global attention* dapat membantu model memahami konteks kata dalam seluruh kalimat atau paragraf. Pada analisis keuangan, mekanisme ini dapat menilai pentingnya setiap titik data dalam riwayat harga untuk memprediksi tren masa depan. Di bidang medis, *global attention* dapat digunakan untuk mengidentifikasi wilayah penting pada citra medis yang berkaitan dengan diagnosis. Selain meningkatkan akurasi prediksi, arsitektur ini juga memberikan keuntungan dari sisi interpretabilitas. Bobot perhatian yang dihasilkan dapat divisualisasikan sehingga pengguna dapat memahami elemen mana yang paling mempengaruhi keputusan model. Hal ini penting untuk membangun kepercayaan pada sistem berbasis kecerdasan

buatan, terutama pada aplikasi yang memerlukan transparansi tinggi seperti perbankan, hukum, atau kesehatan.

Keunggulan lain dari *global attention* adalah fleksibilitasnya untuk diintegrasikan dengan arsitektur jaringan lain. Misalnya, mekanisme ini dapat digabungkan dengan jaringan konvolusional untuk memperkuat fitur yang dihasilkan dari peta spasial, atau dengan jaringan berulang untuk meningkatkan pemrosesan data sekuensial. Secara keseluruhan, Gambar 18 menunjukkan bahwa *arsitektur global attention* bekerja melalui serangkaian tahapan terstruktur: transformasi awal dengan *Dense Layer*, stabilisasi nilai melalui *Batch Normalization*, pengenalan non-linearitas lewat *ReLU*, penyesuaian dimensi sesuai kebutuhan perhatian, normalisasi lanjutan, konversi ke bobot perhatian dengan *Softmax*, pembentukan *Attention Vector*, dan akhirnya penggabungan perhatian dengan masukan untuk menghasilkan keluaran yang lebih fokus dan informatif.



Gambar 19. Mekanisme *Attention* di dalam *Seq2Seq*

Gambar ini menampilkan representasi visual dari cara kerja mekanisme *attention* pada arsitektur *sequence-to-sequence* (*Seq2Seq*), yang digunakan secara luas dalam tugas-tugas pemrosesan bahasa alami seperti penerjemahan mesin, peringkasan teks, dan pengenalan ucapan. Diagram ini menunjukkan bagaimana sistem secara dinamis memfokuskan perhatian pada bagian-bagian tertentu dari *input sequence* ketika menghasilkan setiap elemen pada *output sequence*. Pada bagian bawah diagram terlihat *input sequence* yang terdiri dari token "I", "AM", "A", dan "RESEARCHER". Masing-masing token direpresentasikan dalam bentuk blok kuning yang kemudian diproses melalui lapisan penyandi (*encoder*). Proses ini mengubah setiap token menjadi representasi vektor, yang memuat informasi kontekstual dan semantik dari kata tersebut, sekaligus mempertimbangkan urutan dan hubungan antar token.

Blok kuning ini membentuk keluaran dari *encoder* yang selanjutnya digunakan oleh mekanisme *attention*. Pada gambar, hubungan antara keluaran *encoder* dan vektor perhatian (*attention vector*) diilustrasikan melalui garis merah yang terhubung ke lingkaran berisi nilai bobot (*attention weights*). Nilai bobot ini menunjukkan seberapa besar perhatian yang diberikan model kepada setiap token *input* saat menghasilkan kata tertentu di *output*. Contohnya, ketika sistem akan menghasilkan kata pertama pada *output sequence*, yaitu "JE" (bahasa Prancis untuk "I"), nilai bobot perhatian tertinggi adalah 0,5 untuk kata "I", diikuti 0,3 untuk kata "AM", dan masing-masing 0,1 untuk kata "A" dan "RESEARCHER". Hal ini mencerminkan bahwa kata "JE" paling relevan dengan kata "I" dalam *input sequence*, namun informasi dari kata "AM" dan lainnya tetap dipertimbangkan dalam jumlah yang lebih kecil.

Nilai-nilai bobot ini digunakan untuk menghitung *context vector*, yang merupakan representasi gabungan dari semua keluaran *encoder* yang diberi bobot sesuai relevansinya. *Context vector* ini kemudian menjadi masukan bagi *decoder* untuk menghasilkan kata pada *output sequence*. Bagian tengah diagram menampilkan blok hijau yang merepresentasikan proses di *decoder*. Setiap blok hijau menerima informasi dari token *output* sebelumnya dan *context vector* untuk menghasilkan kata berikutnya. Pada awal proses, *decoder* menerima simbol awal (*start token*), yang pada gambar ditandai sebagai "<S>". Dari titik ini, *decoder* mulai memproduksi kata "JE", kemudian "SUIS" (bahasa Prancis untuk "am"), lalu "CHERCHEUR" (bahasa Prancis untuk "researcher"), dan akhirnya simbol akhir (*end token*) "<S>" untuk menandakan akhir kalimat. Di bagian atas diagram terlihat blok merah yang melambangkan *attention vector* dan *context vector*. Hubungan antara blok-blok ini menggambarkan bagaimana informasi dari *encoder* disesuaikan secara dinamis melalui pembobotan untuk setiap langkah keluaran. Tidak semua token *input* memiliki bobot yang sama pada setiap langkah; bobot ini berubah tergantung pada kata yang sedang diprediksi.

Mekanisme *attention* pada *Seq2Seq* memiliki beberapa manfaat utama. Pertama, ia mengatasi keterbatasan model tradisional yang hanya mengandalkan *context vector* tunggal yang dihasilkan pada akhir *encoder*. Dalam model klasik tanpa *attention*, semua informasi dari *input sequence* harus dikodekan ke dalam satu vektor tetap panjang, yang menyulitkan model dalam memproses kalimat panjang. Dengan *attention*, model dapat melihat kembali seluruh keluaran *encoder* pada setiap langkah *decoder*, sehingga lebih fleksibel dan akurat dalam memilih informasi yang relevan. Kedua, *attention* membuat proses penerjemahan

atau pemetaan urutan menjadi lebih interpretatif. Dengan adanya bobot perhatian, kita dapat memvisualisasikan bagian mana dari *input sequence* yang paling berpengaruh terhadap kata tertentu di *output*. Hal ini tidak hanya membantu pengembang memahami perilaku model, tetapi juga bermanfaat dalam bidang yang memerlukan transparansi tinggi, seperti penerjemahan medis atau hukum.

Dalam diagram ini, perbedaan ketebalan garis merah yang menghubungkan keluaran *encoder* dengan *context vector* dapat diartikan sebagai representasi visual dari kekuatan bobot perhatian. Garis dengan bobot tinggi, seperti dari "I" ke *context vector* saat menghasilkan "JE", digambarkan lebih menonjol, sedangkan garis dengan bobot kecil digambarkan lebih tipis. Mekanisme *attention* juga memungkinkan model untuk menangani perbedaan panjang kalimat antara bahasa sumber dan bahasa target. Dalam penerjemahan, satu kata dalam bahasa sumber bisa diterjemahkan menjadi beberapa kata di bahasa target, atau sebaliknya. Dengan *attention*, model dapat memilih dan menggabungkan informasi dari beberapa kata *input* untuk menghasilkan terjemahan yang lebih alami.

Selain penerjemahan bahasa, *attention* pada *Seq2Seq* dapat diterapkan dalam berbagai domain lain. Dalam *speech recognition*, model dapat memfokuskan perhatian pada bagian tertentu dari sinyal audio untuk mengenali kata yang sedang diucapkan. Dalam *image captioning*, mekanisme ini dapat diarahkan untuk memberi fokus pada bagian tertentu dari gambar saat menghasilkan deskripsi. Dari sudut pandang teknis, diagram ini memperlihatkan arsitektur yang khas: *encoder* di sisi kiri memproses seluruh *input sequence*, menghasilkan keluaran yang kemudian digunakan oleh *attention mechanism* untuk menghasilkan

context vector. *Context vector* ini bersama *decoder state* digunakan untuk memprediksi kata pada setiap langkah keluaran. Proses ini diulang hingga *end token* dihasilkan, menandakan akhir dari *output sequence*. Kombinasi warna dalam diagram juga membantu membedakan peran masing-masing komponen: kuning untuk *encoder*, hijau untuk *decoder*, dan merah untuk komponen *attention*. Pembagian ini membuat alur data lebih mudah diikuti, dari masukan hingga keluaran akhir.

Secara konseptual, *attention* dapat dipandang sebagai cara bagi model untuk “mengingat dengan selektif”. Alih-alih mengandalkan ingatan tunggal yang memuat semua informasi, model dapat melihat kembali semua detail dan memilih mana yang paling relevan pada saat tertentu. Pendekatan ini lebih menyerupai cara kerja manusia dalam memahami dan memproses bahasa, di mana kita tidak mengingat semua kata sekaligus, tetapi memfokuskan perhatian pada bagian yang relevan dengan apa yang ingin kita katakan atau jawab. Dengan melihat Gambar 19, kita dapat memahami bahwa keberhasilan *Seq2Seq* modern dalam berbagai tugas pemrosesan bahasa alami banyak bergantung pada mekanisme *attention*. Tidak hanya meningkatkan akurasi, tetapi juga memberikan kemampuan interpretasi yang lebih baik dan fleksibilitas dalam menangani variasi panjang dan struktur urutan.

Manfaat dalam menghadapi kondisi pasar yang volatil

Penerapan mekanisme *attention* pada model *hybrid* memiliki peran penting dalam menjaga kualitas keluaran, terutama ketika pasar mengalami gejolak yang signifikan. Pada situasi seperti ini, data pasar sering kali dipenuhi oleh *noise* akibat reaksi emosional, perubahan

musiman, maupun kejadian mendadak yang berasal dari faktor eksternal. Mekanisme ini berfungsi sebagai filter adaptif yang mampu menyesuaikan bobot (*weight*) pada periode dan fitur tertentu, sehingga fokus model tetap tertuju pada informasi yang relevan sambil mengabaikan gangguan yang bersifat sementara. Dalam kerangka *deep learning*, *attention* bekerja dengan memberikan bobot yang lebih besar pada elemen input yang memiliki pengaruh dominan terhadap prediksi akhir. Saat volatilitas meningkat, kemampuan ini menjadi semakin berharga karena sinyal utama sering tersembunyi di tengah fluktuasi harga dan volume yang tidak menentu. Dengan mengutamakan elemen-elemen kunci tersebut, model dapat menjaga ketepatan prediksi meskipun pola pasar berubah secara cepat.

Salah satu kekuatan utama *attention* adalah kemampuannya melakukan penyesuaian secara waktu nyata (*real-time adjustment*). Karena data pasar bergerak secara kontinu dan dapat berubah drastis dalam hitungan detik, *attention* memungkinkan model mendeteksi pergeseran pola dengan cepat lalu menyesuaikan distribusi bobotnya sesuai kebutuhan. Dengan begitu, kejadian sementara seperti berita singkat atau pergerakan musiman tidak akan mengganggu stabilitas keluaran secara signifikan. Ketika diintegrasikan dalam model *hybrid* seperti CNN-BiGRU atau CNN-LSTM, keunggulan ini menjadi lebih kuat. CNN berperan dalam mengekstraksi pola spasial dari data multivariat, sementara BiGRU atau LSTM mengelola dependensi temporal baik jangka pendek maupun jangka panjang. *Attention* kemudian menggabungkan hasil keduanya dengan memfokuskan bobot pada titik waktu dan fitur yang paling relevan, khususnya pada periode volatilitas tinggi.

Salah satu ilustrasi penerapan mekanisme ini dapat dilihat pada penggunaan indeks perhatian investor (*investor attention indices*) yang bersumber dari berita daring, media sosial, dan tren pencarian. Perubahan cepat pada indeks tersebut sering mendahului pergerakan harga signifikan. Dengan memasukkan informasi ini ke dalam *attention*, model mampu mengantisipasi perubahan tren sebelum dampaknya terlihat jelas di pasar, sehingga respons prediksi menjadi lebih cepat dan andal.


Selain itu, *attention* juga membantu meredam efek *overreaction* pasar. Dalam kondisi lonjakan harga atau penurunan tajam yang dipicu faktor psikologis atau kabar sesaat, mekanisme ini membedakan antara sinyal dengan dampak jangka panjang dan gangguan sementara. Dengan demikian, prediksi menjadi lebih selaras dengan tren fundamental ketimbang sekadar bereaksi terhadap fluktuasi spontan. Fleksibilitas *attention* juga tampak dalam kemampuannya beradaptasi terhadap perubahan rezim pasar (*market regime change*). Pada situasi normal, bobot perhatian dapat merata atau mengikuti pola historis yang konsisten. Namun, ketika terjadi perubahan ekstrem seperti krisis keuangan atau lonjakan volatilitas global, fokus bobot dapat segera dialihkan ke indikator dan periode yang paling relevan dengan situasi baru. Penyesuaian cepat ini menghindarkan keterlambatan respons yang berpotensi memperburuk dampak gejolak.

Aspek lain yang menguntungkan adalah peningkatan interpretabilitas hasil prediksi. Bobot *attention* dapat divisualisasikan dalam bentuk *heatmap*, yang memperlihatkan periode dan fitur dominan dalam proses prediksi saat volatilitas tinggi. Visualisasi ini mempermudah


validasi hasil sekaligus membantu pemangku kepentingan memahami dasar keputusan model.

Integrasi *attention* dalam kerangka prediksi di pasar yang bergejolak juga mendorong strategi manajemen risiko yang lebih proaktif. Dengan kemampuan mengidentifikasi titik kritis yang memicu perubahan arah pasar, pelaku pasar dapat menyusun langkah mitigasi lebih awal. Hal ini mendukung tujuan utama prediksi finansial, yakni memberikan dasar yang kuat bagi pengambilan keputusan yang tepat waktu dan berbasis data.

Dari sisi operasional, penerapan *attention* untuk mengatasi volatilitas memerlukan alur pengolahan data yang terstruktur. Proses dimulai dengan pengumpulan data dari berbagai sumber, diikuti normalisasi untuk menyamakan skala, serta pembersihan dari *noise* yang tidak relevan. Setelah data diproses oleh arsitektur *hybrid, attention* mengalokasikan bobot secara optimal untuk menjaga kualitas prediksi. Dengan berbagai keunggulan tersebut, mekanisme *attention* dalam model *hybrid* tidak hanya meningkatkan ketepatan prediksi, tetapi juga menjaga konsistensi performa di tengah dinamika pasar yang tidak menentu. Kemampuannya beradaptasi, memfilter informasi, dan memastikan keluaran tetap relevan menjadikannya solusi yang efektif untuk menghadapi tantangan pasar keuangan yang kompleks.



g. 6. Model performance on different fault types for Pronto dataset.



g. 7. Ablation study of DyGATAD model performance for different fault types on the Pronto dataset

Gambar 20. Perbandingan Kinerja Model dengan dan tanpa *Attention* pada Anomali

Gambar ini memperlihatkan perbandingan kinerja beberapa pendekatan deteksi anomali yang diukur melalui dua indikator utama, yaitu *Area Under Curve (AUC)* dan *F1-score*. Visualisasi disusun dalam dua kelompok besar. Kelompok pertama, pada bagian atas, menampilkan performa model untuk berbagai kategori gangguan. Kelompok kedua, pada bagian bawah, menampilkan kajian *ablation* yang memperlihatkan dampak penghapusan atau perubahan komponen tertentu pada arsitektur model utama. Panel bagian atas memuat dua grafik—*AUC* di sebelah kiri dan *F1-score* di sebelah kanan—yang mengukur kemampuan model dalam mendeteksi anomali pada tiga kategori gangguan: *Air leakage*, *Air blockage*, dan *Diverted flow*. Rata-rata kinerja dari ketiga kategori ini juga ditampilkan untuk memberikan gambaran umum. Warna batang merepresentasikan model yang berbeda, termasuk model dengan

mekanisme *attention* dan model tanpa mekanisme tersebut. Dari perbandingan ini, terlihat bahwa penggunaan *attention* memberikan keunggulan konsisten pada kedua metrik, terutama pada skenario *Diverted flow* yang relatif lebih menantang, di mana perbedaan kinerjanya tampak paling jelas. Hal ini menunjukkan bahwa *attention* memungkinkan model memusatkan perhatian pada informasi yang relevan sehingga mampu memberikan hasil yang lebih baik, bahkan dalam kondisi data yang kompleks.

Bagian bawah gambar menampilkan hasil kajian *ablation* pada model *Dynamic Graph Attention for Anomaly Detection (DyGATAD)*. Pengujian dilakukan dengan menghilangkan atau memodifikasi komponen seperti *topology learning*, fitur kontrol, informasi temporal, serta dengan mengganti graf dinamis menjadi graf statis. Setiap konfigurasi dievaluasi dengan metrik *AUC* dan *F1-score* untuk mengukur perubahan kinerja yang terjadi. Pada metrik *AUC* di panel kiri bawah, model penuh *DyGATAD* yang ditunjukkan dengan warna ungu tua secara konsisten unggul dibandingkan variasi yang dimodifikasi. Penghapusan informasi temporal (*w/o time*) menghasilkan penurunan kinerja yang cukup besar pada semua kategori, khususnya pada *Diverted flow*. Hal ini menegaskan pentingnya dimensi waktu dalam mendeteksi perubahan yang bersifat dinamis. Demikian pula, mengganti graf dinamis dengan graf statis (*w. static graph*) berdampak negatif, menunjukkan bahwa kemampuan penyesuaian struktur graf terhadap perubahan data sangat berpengaruh terhadap hasil akhir.

Pola yang serupa juga terlihat pada *F1-score* di panel kanan bawah. Model penuh *DyGATAD* tetap mempertahankan skor tertinggi pada hampir semua kategori gangguan. Penurunan paling signifikan

kembali terlihat pada konfigurasi tanpa informasi temporal, yang mengindikasikan bahwa komponen ini memiliki peran sentral dalam menjaga keseimbangan antara presisi dan kemampuan menangkap seluruh kasus anomali. Dari keseluruhan hasil visualisasi ini, dapat ditarik beberapa poin penting. Pertama, mekanisme *attention* terbukti memberikan stabilitas dan keunggulan kinerja pada berbagai jenis gangguan, dengan kontribusi terbesar pada kasus yang lebih kompleks. Kedua, informasi temporal menjadi faktor yang sangat memengaruhi kemampuan model dalam mendeteksi anomali, terutama ketika pola perubahannya terjadi secara bertahap atau berkala. Ketiga, pemanfaatan graf dinamis menawarkan kelebihan nyata dalam mendukung adaptasi model terhadap kondisi data yang terus berubah, yang tidak dapat dicapai oleh graf statis. Keunggulan ini tidak hanya relevan dalam ranah pengembangan model, tetapi juga memiliki implikasi langsung pada penerapannya di dunia nyata. Pada sistem seperti pemantauan mesin industri, pengawasan distribusi air, atau deteksi penyimpangan dalam jaringan energi, model dengan kombinasi *attention*, informasi temporal, dan graf dinamis berpotensi memberikan respons yang lebih cepat, akurat, dan adaptif terhadap kondisi yang berubah. Hal ini pada akhirnya dapat membantu mengurangi kerugian, mempercepat penanganan gangguan, serta menjaga keberlangsungan operasi.

Visualisasi seperti ini juga memiliki nilai strategis sebagai sarana komunikasi antara pengembang sistem dan pihak pengambil keputusan. Dengan tampilan yang terstruktur, pembaca dapat langsung memahami perbedaan antarpendekatan tanpa harus menelaah data mentah. Jika diperlukan, analisis visual dapat diperluas dengan menambahkan representasi lain seperti *precision-recall curve* atau distribusi bobot

attention untuk memberikan pemahaman yang lebih mendalam terhadap mekanisme kerja model. Gambar 20 dengan jelas menegaskan bahwa penggabungan *attention*, dimensi waktu, dan graf dinamis bukan hanya memberikan peningkatan kinerja, tetapi juga membentuk fondasi yang kuat bagi sistem deteksi anomali yang mampu beradaptasi terhadap berbagai tantangan di lingkungan operasional yang dinamis.

Bab 6. Pengolahan Data Pasar Saham

Karakteristik dan sumber data

Data pasar saham harian diperoleh dari beragam platform dan bursa dengan format serta keterbatasan yang berbeda-beda. Sumber populer seperti *Yahoo! Finance* menyajikan himpunan data yang mencakup harga pembukaan, harga tertinggi, harga terendah, harga penutupan, dan volume perdagangan, dilengkapi pula dengan data turunan seperti opsi maupun indeks volatilitas. Bursa saham nasional, termasuk Bursa Malaysia, Jakarta Composite Index, Kuala Lumpur Composite Index, dan Philippine Stock Exchange, menjadi rujukan utama bagi harga penutupan harian beserta variabel pendukung. Sumber lain seperti basis data keuangan komersial *Thomson Reuters Financial Datastream* atau dataset khusus *StockPTV* menyediakan rangkaian data harian yang lebih komprehensif, meliputi harga, imbal hasil, serta volume.

Umumnya, data pasar saham harian tersaji dalam format *tabular* yang seragam, mencatat perkembangan informasi pasar dari waktu ke waktu. Elemen yang kerap ditemui meliputi tanggal, harga pembukaan (*Open*), harga tertinggi (*High*), harga terendah (*Low*), harga penutupan (*Close*), dan volume perdagangan, yang dikenal sebagai format OHLCV. Data ini biasanya disimpan dalam bentuk CSV atau basis data terstruktur dengan pengindeksan berurutan menurut tanggal. Dari titik-titik harga OHLC tersebut, dapat diturunkan indikator tambahan seperti imbal hasil atau indeks volatilitas. Meskipun beberapa penyedia komersial memiliki format khusus, struktur OHLCV tetap menjadi standar luas karena kesesuaiannya dengan pemrosesan deret waktu.

Meski tersedia luas dan berformat baku, data publik pasar saham memiliki keterbatasan tertentu. Masalah kualitas kerap muncul, bahkan pada sumber ternama, sehingga perlu pemeriksaan teliti. Sebagian dataset publik hanya memuat harga penutupan harian tanpa detail yang diperlukan untuk analisis berfrekuensi tinggi. Kedalaman historis data juga dapat terbatas, atau tidak mencakup variabel penting seperti *order book* dan volume perdagangan intraday. Selain itu, terdapat potensi *survivorship bias* maupun perbedaan pelaporan antar bursa yang dapat memengaruhi keandalan model prediksi. Dalam kondisi pasar yang volatil, mekanisme *attention* dalam model *hybrid* berperan menjaga mutu keluaran dengan melakukan penyesuaian bobot (*weight adjustment*) secara dinamis. Kemampuan ini membuat model memusatkan fokus pada periode serta fitur relevan, sehingga gangguan musiman dan kejutan pasar dapat diredam. Saat data mencerminkan fluktuasi ekstrem akibat sentimen atau peristiwa eksternal, *attention* bertindak sebagai filter adaptif yang menyeleksi informasi bernilai tinggi dan menyisihkan *noise* yang kurang penting.

Penggabungan *attention* dengan arsitektur *deep learning* seperti CNN-LSTM atau CNN-BiGRU semakin memperkuat kemampuan memahami pola kompleks. CNN berperan mengekstraksi pola spasial dari data multivariat, sedangkan LSTM atau BiGRU memetakan keterkaitan temporal. *Attention* kemudian memberi prioritas pada komponen terpenting, memastikan prediksi tetap stabil di tengah gejolak pasar. Pendekatan ini sangat bermanfaat ketika data berasal dari beragam kanal, seperti media daring, laporan keuangan, atau indikator teknikal, yang memiliki tingkat relevansi berbeda terhadap pergerakan harga. Dengan pengelolaan yang cermat, data pasar saham harian dapat

menjadi landasan kokoh untuk membangun model prediksi yang andal. Pemeriksaan kualitas data, pemilihan sumber terpercaya, dan penerapan mekanisme *attention* menjadi langkah strategis agar model mampu bekerja optimal, baik pada kondisi normal maupun ketika pasar bergerak cepat.

Tabel 9. Contoh Skema Kolom Data Harga Harian Saham

Date	Open	High	Low	Close	Adj Close	Volume
2025-08-01	6,200	6,250	6,150	6,220	6,220	12,350,000
2025-08-04	6,230	6,280	6,200	6,260	6,260	10,845,000
2025-08-05	6,250	6,300	6,220	6,280	6,280	14,120,000
2025-08-06	6,290	6,340	6,270	6,310	6,310	11,875,000
2025-08-07	6,320	6,360	6,300	6,350	6,350	13,540,000

Tabel ini memperlihatkan rangkaian informasi harga saham harian yang tersusun rapi sesuai urutan tanggal perdagangan. Setiap baris merepresentasikan satu hari bursa, dengan kolom-kolom yang dirancang untuk memberikan pandangan menyeluruh atas dinamika harga serta tingkat aktivitas pasar. Kolom **Date** menjadi penanda waktu yang menjaga urutan kronologis data. Rentang lima hari perdagangan di awal Agustus 2025 menunjukkan kesinambungan informasi, yang penting untuk memahami perkembangan harga dari satu sesi ke sesi berikutnya. Keberadaan urutan ini juga mempermudah penerapan indikator berbasis *time series* yang mengandalkan kesinambungan data.

Kolom **Open** mencerminkan harga pada saat pembukaan perdagangan. Nilai ini sering kali dipengaruhi oleh sentimen yang berkembang sebelum pasar dibuka, seperti berita ekonomi atau perubahan kondisi global. Dalam contoh ini, harga pembukaan menunjukkan pola peningkatan dari 6,200 menjadi 6,320, memberi gambaran bahwa optimisme pasar berkembang dari hari ke hari. Kolom

High menandai harga tertinggi yang tercapai selama sesi berlangsung. Informasi ini memberi sinyal tentang potensi kenaikan intraday yang mampu diraih. Lonjakan hingga 6,360 pada 7 Agustus menjadi titik puncak periode ini, mengisyaratkan adanya kekuatan beli yang cukup kuat. Sebaliknya, kolom **Low** menunjukkan harga terendah yang terbentuk dalam hari tersebut. Selisih antara **High** dan **Low** atau *price range* membantu mengukur volatilitas harian. Dalam data ini, kisaran harga relatif stabil dengan perbedaan sekitar 100 poin, yang menunjukkan bahwa pergerakan harga berada dalam rentang terkendali meskipun tren keseluruhan mengarah ke atas. Kolom **Close** menjadi acuan penting bagi banyak pelaku pasar karena mewakili harga akhir yang disepakati di penghujung sesi. Kenaikan bertahap dari 6,220 ke 6,350 memperlihatkan bahwa dorongan positif berlangsung konsisten di seluruh periode pengamatan. Kolom **Adj Close** atau *adjusted close* memberikan harga penutupan yang telah disesuaikan untuk memperhitungkan faktor seperti dividen atau *stock split*. Penyesuaian ini menjaga relevansi data historis. Dalam tabel ini, nilainya identik dengan **Close** karena tidak terdapat perubahan teknis harga selama periode yang dicatat. Kolom **Volume** mencerminkan total saham yang berpindah tangan dalam satu hari. Nilai yang besar menandakan tingginya partisipasi pasar dan tingkat likuiditas yang baik. Lonjakan volume pada 5 Agustus, yang mencapai lebih dari 14 juta lembar, berpotensi mengindikasikan adanya peristiwa atau informasi yang memicu peningkatan aktivitas perdagangan. Struktur data seperti ini memudahkan integrasi ke berbagai sistem, baik untuk pembuatan *candlestick chart*, pemantauan tren, hingga pengembangan model *machine learning*. Gabungan harga pembukaan, tertinggi, terendah,

penutupan, dan volume menyediakan basis yang kaya untuk menggali pola pergerakan harga.

Bagi manajer investasi, informasi ini mendukung pengambilan keputusan yang lebih terukur. Perbandingan antara **Open** dan **Close** memungkinkan identifikasi kecenderungan pasar harian, apakah mengarah *bullish* atau *bearish*. Sementara itu, hubungan antara pergerakan harga dan volume membantu dalam mendeteksi fase akumulasi maupun distribusi oleh pelaku besar. Tabel ini juga berfungsi sebagai arsip yang memudahkan pembuatan laporan performa saham. Penyajian yang konsisten menjadikan data mudah dipahami tidak hanya oleh analis teknis, tetapi juga oleh pihak manajemen atau investor yang menginginkan ringkasan singkat namun informatif. Selain sebagai catatan historis, format seperti ini dapat diolah menjadi input untuk sistem perdagangan otomatis (*automated trading*). Dengan dukungan algoritma yang tepat, pola-pola yang terekam di tabel dapat digunakan untuk memprediksi pergerakan harga berikutnya dan mengeksekusi strategi beli atau jual secara optimal. Dengan demikian, Tabel 9 berperan sebagai landasan yang kokoh untuk mengamati, mengevaluasi, dan memproyeksikan pergerakan harga saham. Kejelasan kolom, kelengkapan data, serta urutan kronologis yang rapi menjadikannya sumber informasi yang dapat diandalkan bagi berbagai pihak di dunia pasar modal.



Gambar 21. Pergerakan IHSG 2 Januari – 8 Agustus 2025

Garis pada ilustrasi ini menggambarkan dinamika *Indeks Harga Saham Gabungan* sepanjang awal Januari hingga awal Agustus 2025. Pergerakan yang terekam menunjukkan bagaimana pasar merespons rangkaian faktor ekonomi domestik, arus sentimen global, dan aktivitas para pelaku investasi. Memasuki awal Januari, IHSG berada di kisaran 7.100 dan sempat bergerak stabil sebelum mengalami pelemahan yang cukup tajam di pertengahan bulan. Penurunan berlanjut hingga menembus di bawah 6.600 pada awal Februari, mencerminkan tekanan yang cukup besar terhadap harga saham. Kondisi ini berlangsung di tengah gejolak yang sering kali menandai awal tahun, ketika investor menata ulang strategi dan merespons isu-isu makro yang berkembang.

Februari ditandai oleh fluktuasi intens di rentang 6.600 hingga 6.800. Beberapa kali terjadi kenaikan singkat, namun segera diikuti koreksi, menandakan pasar tengah mencari arah yang lebih mantap. Pada Maret hingga awal April, indeks jatuh lebih dalam hingga mendekati level

6.000 — titik terendah dalam periode ini. Dari sini, pasar mulai membentuk *rebound* yang terlihat cukup konsisten. Periode April hingga Mei menunjukkan kenaikan yang bertahap. IHSG kembali menembus 6.800 dan bahkan mendekati 7.200 di pertengahan Mei, sebuah sinyal masuknya sentimen positif yang kemungkinan didorong oleh kinerja emiten yang membaik atau berita optimistis dari sektor-sektor kunci. Namun, pada Juni, tren penguatan tersebut terhenti oleh koreksi yang membawa indeks kembali ke kisaran 6.800–6.900. Walau demikian, pasar tetap bertahan di atas titik rendah sebelumnya, menandakan keyakinan yang masih terjaga.

Juli menjadi titik penting dengan kenaikan signifikan hingga menembus 7.400 dan mencapai sekitar 7.600 di akhir bulan. Lonjakan ini berpotensi dipicu oleh aliran modal masuk, rilis laporan keuangan yang positif, atau perkembangan global yang menguntungkan bagi pasar negara berkembang. Awal Agustus kemudian memperlihatkan pergerakan mendatar di kisaran 7.400–7.500, sebuah fase konsolidasi di mana pasar tampak menunggu pemicu baru untuk melanjutkan langkah. Jika ditelusuri lebih lanjut, periode ini membentuk rangkaian tahapan: penurunan awal tahun yang tajam, fase volatil di kuartal pertama, titik terendah pada awal April, pemulihan di kuartal kedua, koreksi singkat di Juni, lonjakan kuat di Juli, dan konsolidasi di awal Agustus. Masing-masing fase menggambarkan interaksi yang kompleks antara faktor ekonomi makro, kebijakan moneter, dinamika sektor industri, serta pengaruh kondisi eksternal seperti pergerakan harga komoditas dan kebijakan pasar global.

Penurunan yang terjadi pada awal tahun dan awal kuartal kedua memperlihatkan bahwa IHSG tidak terlepas dari tekanan eksternal

maupun faktor internal yang memengaruhi persepsi risiko. Namun, kebangkitan setelah April menunjukkan daya tarik pasar yang mampu mengundang minat beli kembali, terutama dari mereka yang mencari momentum pada harga lebih rendah. Penguatan yang berlanjut hingga Juli mengindikasikan bahwa dukungan fundamental cukup kuat untuk menopang tren positif, meskipun sempat terganggu oleh koreksi. Sementara itu, konsolidasi di awal Agustus memberikan sinyal bahwa pelaku pasar sedang menimbang langkah selanjutnya, apakah mempertahankan tren kenaikan atau menyiapkan diri untuk menghadapi penurunan baru. Perjalanan IHSG dalam periode ini mencerminkan ketahanan pasar modal Indonesia menghadapi tantangan dan peluang dalam skala global. Puncak yang dicapai pada akhir Juli menjadi pencapaian signifikan, sementara pergerakan di bulan-bulan sebelumnya menampilkan transisi dari tekanan berat menuju optimisme yang lebih terukur.

Strategi pembersihan dan DataSet

Pengolahan data pasar saham yang berkualitas tidak hanya ditentukan oleh kelengkapan sumbernya, tetapi juga oleh penerapan strategi pembersihan yang tepat. Dua aspek utama dalam proses ini adalah penanganan nilai yang hilang (*missing values*) serta perbaikan pencatatan keliru (*erroneous data points*). Keduanya perlu ditangani secara cermat agar urutan data tetap terjaga dan struktur dasarnya tidak mengalami perubahan yang dapat mengganggu pemrosesan lanjutan. Nilai yang hilang kerap muncul dalam dataset keuangan akibat hari libur bursa, gangguan teknis, atau ketidakkonsistenan pelaporan. Untuk

menjaga kualitas informasi, teknik *imputation* digunakan sebagai solusi. Pendekatan sederhana seperti penggantian dengan nilai rata-rata (*mean imputation*) atau median bermanfaat untuk data dengan distribusi stabil. Sementara itu, dataset yang kompleks dengan pola kehilangan acak sering memerlukan teknik yang lebih maju, seperti *multiple imputation* atau *KNNImputer*, yang mampu mempertahankan distribusi statistik sekaligus meminimalkan bias.

Dalam deret waktu keuangan yang tidak selalu teratur, pendekatan berbasis *state-space modeling* dapat dimanfaatkan untuk mengisi kekosongan data tanpa mengganggu urutan temporalnya. Strategi ini membuat penyesuaian berlangsung mulus, sehingga pergerakan harga, volume, dan indikator lain tetap konsisten dalam rentang waktu yang dianalisis. Selain mengatasi nilai yang hilang, perbaikan catatan yang keliru juga menjadi bagian penting. Kesalahan dapat muncul dalam bentuk harga yang tidak wajar, volume perdagangan yang melampaui batas normal, atau tanggal yang tidak sesuai jadwal bursa. Identifikasi anomali dilakukan melalui deteksi pencilan (*outlier detection*), algoritme klasterisasi, atau aturan berbasis logika yang membandingkan entri terhadap kisaran nilai wajar. Setelah ditemukan, kesalahan dapat diperbaiki dengan teknik *imputation* atau, jika perlu, dihapus secara hati-hati agar tidak menghilangkan informasi signifikan.

Menjaga keseimbangan antara pembersihan dan integritas data merupakan hal yang penting. Menghapus terlalu banyak catatan bisa menghilangkan sinyal pasar berharga, sedangkan membiarkan kesalahan dapat menurunkan akurasi model. Karena itu, setiap langkah pembersihan harus mempertimbangkan dampaknya terhadap kualitas keseluruhan dataset.

Penerapan strategi pembersihan yang efektif memberikan pengaruh besar terhadap kinerja model prediksi. Nilai yang hilang atau keliru, bila dibiarkan, berpotensi menghasilkan estimasi bias, menurunkan kekuatan statistik, dan melemahkan keandalan hasil. Penggunaan teknik seperti *multiple imputation* atau pendekatan berbasis KNN dapat mengurangi risiko pelatihan model pada data yang cacat. Di sisi lain, perbaikan data keliru meningkatkan rasio sinyal terhadap *noise*, sehingga akurasi dan kejelasan interpretasi model meningkat. Dengan mengintegrasikan strategi pembersihan yang terstruktur ke dalam pemodelan keuangan, prediksi menjadi lebih stabil dan dapat diandalkan. Setiap tahap—mulai dari deteksi masalah, pemilihan teknik penanganan, hingga evaluasi hasil—memegang peran penting untuk memastikan model mampu merepresentasikan kondisi pasar secara tepat, baik pada saat pasar normal maupun ketika volatilitas meningkat.

Tabel 10. Teknik Pengisian Nilai Kosong dan Dampaknya

Teknik Pengisian	Deskripsi	Keunggulan	Keterbatasan
Hapus Baris (<i>Listwise Deletion</i>)	Menghapus seluruh baris jika terdapat nilai kosong.	Implementasi sederhana; bebas dari <i>imputer</i> .	Mengurangi jumlah sampel dan menurunkan presisi; dapat menyebabkan bias jika data tidak <i>MCAR</i> .
Mean / Median / Mode	Mengganti nilai kosong dengan rata-rata, median, atau modus variabel.	Mudah dan cepat; menjaga nilai sentral.	Dapat meredam korelasi antar variabel; kurang cocok untuk distribusi abnormal.

Forward / Backward Fill	Mengisi dengan nilai sebelumnya atau selanjutnya pada urutan data (<i>time series</i>).	Alami untuk data berurutan; sederhana.	Tidak cocok untuk data fluktuatif atau tidak stabil.
Hot-Deck / Cold-Deck	Menggantikan dengan nilai dari observasi lain—dalam dataset (<i>hot-deck</i>) atau dataset lain (<i>cold-deck</i>).	Mempertahankan distribusi asli.	Pemilihan “donor” mungkin subjektif; berpotensi bias jika dataset berbeda.
Regresi (<i>Single Imputation</i>)	Mengestimasi nilai kosong berdasarkan model regresi dari variabel lainnya.	Memanfaatkan hubungan antar variabel.	Kurang menunjukkan ketidakpastian hasil imputasi; dapat memberi kesan terlalu pasti.
Multiple Imputation (<i>MICE</i>)	Menghasilkan beberapa versi dataset dengan imputasi yang berbeda lalu digabung.	Mengakomodasi keragaman dan ketidakpastian; lebih valid secara statistik.	Lebih kompleks dan memakan waktu.
Predictive Mean Matching (<i>PMM</i>)	Mengganti nilai kosong dengan nilai nyata dari observasi yang mirip.	Menghasilkan imputasi yang realistis.	Memerlukan data yang memadai untuk menemukan pasangan yang sesuai.
Imputasi Berbasis <i>Machine Learning</i>	Menggunakan model seperti	Dapat menangani pola	Memerlukan sumber daya

	KNN, regresi, atau jaringan saraf untuk memprediksi nilai yang hilang.	kompleks dan nonlinear.	komputasi tinggi dan proses <i>tuning</i> model yang optimal.
--	--	-------------------------	---

Tabel ini menyajikan gambaran komprehensif mengenai berbagai teknik yang dapat digunakan untuk mengisi nilai kosong pada data. Setiap pendekatan dijelaskan secara ringkas, dilengkapi dengan keunggulan serta keterbatasan utama yang mungkin muncul ketika teknik tersebut diterapkan. Pemahaman terhadap ragam strategi ini memberikan landasan yang solid dalam pengelolaan data sehingga kualitas informasi tetap terjaga. Pendekatan **hapus baris (*listwise deletion*)** merupakan strategi yang paling sederhana, yaitu menghilangkan seluruh baris data apabila terdapat setidaknya satu nilai kosong. Langkah ini membuat proses pembersihan data menjadi cepat dan tidak memerlukan algoritma tambahan untuk melakukan *imputation*. Meskipun demikian, pengurangan jumlah data yang signifikan dapat terjadi, terutama bila nilai kosong tersebar di banyak variabel. Kehilangan sampel ini dapat memengaruhi daya representasi data dan meningkatkan potensi *bias* apabila nilai yang hilang tidak terjadi secara acak (*missing completely at random*).

Teknik **mean, median, atau mode** menawarkan solusi cepat dengan mengganti nilai kosong menggunakan nilai tengah distribusi. Pilihan mean digunakan untuk data numerik yang cenderung simetris, median lebih tepat untuk data yang memiliki pencilan (*outliers*), dan mode digunakan untuk data kategorikal. Kelebihan teknik ini terletak pada kemudahannya dan kemampuannya menjaga nilai pusat. Namun, pengisian dengan nilai tengah dapat mengurangi variasi alami data dan

memengaruhi hubungan antar variabel, terutama bila distribusi data tidak normal. Untuk data yang memiliki urutan waktu seperti *time series*, **forward fill** dan **backward fill** menjadi alternatif yang logis. Forward fill mengambil nilai dari entri sebelumnya untuk mengisi kekosongan, sedangkan backward fill memanfaatkan nilai dari entri setelahnya. Keduanya mempertahankan kontinuitas dalam data yang stabil. Namun, bila data bersifat sangat dinamis atau terpengaruh oleh faktor eksternal yang cepat berubah, teknik ini berisiko menghasilkan nilai yang jauh dari kondisi aktual.


Pendekatan **hot-deck** dan **cold-deck** berupaya menjaga keaslian distribusi dengan mengambil nilai dari entri yang benar-benar ada. Pada hot-deck, nilai diperoleh dari dataset yang sama, sementara cold-deck memanfaatkan dataset berbeda sebagai sumber. Keunggulannya terletak pada kemampuannya menjaga struktur data yang realistis. Meski demikian, pemilihan *donor* dapat menimbulkan subjektivitas, dan perbedaan karakteristik antar dataset dapat menyebabkan ketidaksesuaian nilai yang diisikan. Teknik **regresi (*single imputation*)** memanfaatkan hubungan antar variabel untuk memprediksi nilai kosong. Model regresi dibangun berdasarkan variabel lain yang relevan, kemudian digunakan untuk menghasilkan perkiraan nilai yang hilang. Strategi ini mampu memberikan hasil yang konsisten dengan pola hubungan yang ada di dalam data. Namun, karena hanya menghasilkan satu nilai prediksi, ketidakpastian imputasi tidak tergambarkan, sehingga berpotensi memberi kesan seolah nilai tersebut benar-benar pasti.

Berbeda dari regresi tunggal, **multiple imputation (*MICE*)** menggunakan beberapa skenario imputasi berbeda untuk nilai yang sama. Setiap skenario menghasilkan versi dataset yang bervariasi, lalu

hasilnya digabung untuk menghasilkan estimasi akhir. Teknik ini mempertimbangkan variasi dan ketidakpastian, sehingga hasilnya secara statistik lebih kuat. Meski begitu, prosesnya memerlukan waktu lebih lama dan perhitungan yang lebih kompleks, sehingga menuntut sumber daya yang memadai. Pendekatan **predictive mean matching (PMM)** berfokus pada realisme hasil imputasi. Nilai kosong digantikan dengan nilai aktual dari observasi yang memiliki karakteristik paling mirip, sehingga nilai yang dihasilkan tetap berada dalam rentang data yang wajar. Keberhasilan teknik ini sangat bergantung pada ketersediaan data pembanding yang memadai untuk memastikan pasangan yang relevan dapat ditemukan.

Terakhir, **imputasi berbasis *machine learning*** memanfaatkan kekuatan model-model canggih seperti *k-nearest neighbors* (KNN), regresi nonlinier, atau *neural networks* untuk memprediksi nilai yang hilang. Keunggulannya terletak pada kemampuannya mengenali pola yang kompleks, termasuk hubungan nonlinier antar variabel, yang sulit ditangkap oleh teknik sederhana. Namun, strategi ini memerlukan sumber daya komputasi yang besar dan proses *tuning* model yang tepat agar kinerjanya optimal. Dari seluruh teknik yang dipaparkan, terlihat bahwa setiap pendekatan memiliki situasi ideal masing-masing. Pada dataset kecil dengan nilai kosong yang jarang, teknik sederhana seperti mean atau median dapat digunakan secara efisien. Sebaliknya, pada dataset besar yang kompleks, teknik berbasis *machine learning* atau multiple imputation akan lebih tepat untuk menjaga integritas dan kekayaan informasi. Kombinasi antar teknik juga sering digunakan untuk mencapai hasil yang lebih seimbang, misalnya memulai dengan forward fill untuk

mengisi kekosongan singkat pada *time series*, kemudian melanjutkan dengan PMM untuk bagian yang lebih kompleks.



Gambar 22. Alur Proses Pembersihan Data

Gambar ini menampilkan alur terstruktur untuk mengolah *raw data* menjadi informasi yang telah melalui tahap pembersihan. Proses dimulai dari data mentah yang umumnya berasal dari berbagai sumber seperti basis data, *file CSV*, *API*, sensor, atau formulir masukan. Pada tahap awal ini, data sering kali mengandung nilai yang hilang, format yang tidak seragam, atau kesalahan pengetikan yang dapat mengganggu tahap pemrosesan berikutnya. Tahap berikutnya adalah *parse / data check*, di mana data diperiksa berdasarkan *user-defined schema*. Skema ini memuat aturan mengenai tipe data, format, hingga batas nilai yang diperbolehkan. Proses ini berfungsi memastikan setiap elemen sesuai dengan standar yang telah ditetapkan pengguna. Apabila ditemukan

ketidaksesuaian, data tersebut masuk kategori *erroneous data* dan diarahkan menuju proses *manual correction*.

Pada proses *manual correction*, dilakukan pemeriksaan ulang dan perbaikan seperti penyesuaian format atau pengisian nilai yang hilang. Setelah diperbaiki, data kembali diuji pada tahap *parse / data check*. Sementara itu, data yang dinyatakan benar akan menjadi *validated data*, yaitu data yang akurat, konsisten, dan sesuai aturan, sehingga siap digunakan pada tahap selanjutnya. Langkah *split / summarize* memisahkan data tervalidasi menjadi beberapa set sesuai tujuan, misalnya *cleansed training data* untuk melatih model, dan *cleansed test data* untuk menguji performa model. Dari tahap ini juga dihasilkan *data profile*, yang berisi ringkasan karakteristik data seperti distribusi nilai dan frekuensi kemunculan, sehingga memudahkan pemahaman atas struktur data yang ada.

Alur ini bersifat iteratif, memungkinkan perbaikan berulang hingga kualitas data memenuhi standar. Peran manusia tetap esensial di tahap koreksi, karena intuisi dan wawasan bidang sering kali diperlukan untuk mengatasi masalah yang tidak dapat dideteksi otomatis. Skema yang didefinisikan pengguna menjadi fondasi penting dalam memastikan data relevan dan sesuai konteks penggunaan, seperti dalam transaksi keuangan yang mengharuskan nilai positif atau tanggal yang valid. Proses pemisahan dan peringkasan tidak hanya membantu menghindari *overfitting* pada model, tetapi juga mengurangi beban komputasi dengan hanya memproses data yang relevan. Pendekatan ini sangat berguna ketika menggabungkan data dari berbagai sumber, karena memudahkan konsolidasi sekaligus mengurangi potensi salah tafsir. Setiap tahap dapat diimplementasikan dengan beragam alat, mulai dari proses ETL (*Extract,*

Transform, Load) untuk pengambilan *raw data*, skrip Python atau SQL untuk validasi, hingga perangkat analitik untuk pembagian dan pembuatan profil data. Alur ini juga fleksibel, dapat disesuaikan dengan kebutuhan, termasuk untuk pengolahan *real-time* yang mungkin memerlukan validasi otomatis lebih ketat dibanding koreksi manual.

Penyesuaian terhadap nilai outliers

Nilai *outliers* pada data pasar saham adalah pengamatan yang sangat menyimpang dari pola umum dan berpotensi menyesatkan pembacaan hasil serta memengaruhi kualitas keputusan. Untuk mencegah dominasi nilai ekstrem dan mempertahankan sebaran yang wajar, diperlukan penyesuaian yang dirancang secara hati-hati agar struktur distribusi tidak berubah secara signifikan. Proses identifikasi *outliers* dapat menggunakan pendekatan statistik seperti Z-score, *interquartile range* (IQR), maupun *winsorization*. Dalam *winsorization*, nilai di bawah persentil ke-1 dan di atas persentil ke-99 dibatasi, sehingga pengaruh data yang sangat ekstrem dapat diminimalkan tanpa menghapusnya. Teknik ini menjaga sifat *robust* pada dataset dan mendukung pengambilan keputusan yang memerlukan tingkat akurasi tinggi.

Pendekatan lain yang umum digunakan adalah *robust scaling*, di mana data dipusatkan pada median dan diskalakan berdasarkan IQR. Langkah ini mampu menahan pengaruh *outliers* tanpa mengubah bentuk distribusi, sehingga sangat relevan untuk pasar saham yang kerap mengalami pergerakan harga ekstrem akibat sentimen sesaat atau perilaku perdagangan yang tidak lazim.

Dalam situasi tertentu, teknik deteksi berbasis kepadatan seperti *local outlier factor* membantu menemukan nilai ekstrem yang luput dari metode tradisional. Cara ini memberikan pembedaan yang lebih jelas antara pergerakan pasar yang mencerminkan tren fundamental dengan anomali sementara, sehingga model prediksi dapat memfokuskan perhatian pada sinyal yang benar-benar penting. Penyesuaian nilai ekstrem berdampak positif terhadap rasio sinyal terhadap *noise*, yang pada gilirannya meningkatkan akurasi prediksi dan kejelasan interpretasi. Pengelolaan yang tepat membuat model mampu menggambarkan perilaku pasar secara realistis, tetap peka terhadap peristiwa penting, dan tidak terdistorsi oleh data yang tidak representatif. Dengan menggabungkan *winsorization*, *robust scaling*, dan teknik deteksi lanjutan, data pasar saham dapat disempurnakan sehingga mencerminkan kondisi riil. Pendekatan ini menjadi landasan penting dalam menjaga kestabilan prediksi serta memperkuat dasar pengambilan keputusan di lingkungan keuangan yang dinamis.

Tabel 11. Ambang Deteksi *Outlier* dan Opsi Penyesuaian

Teknik Deteksi	Ambang Umum / Penanda Outlier	Opsi Penyesuaian
<i>Z-score</i>	Nilai absolut $Z > 3$ untuk data yang berdistribusi normal	Batasi (<i>capping</i>), hapus data
<i>IQR (Interquartile Range)</i>	Nilai $< Q1 - 1.5 \times IQR$ atau $> Q3 + 1.5 \times IQR$	<i>Clamping</i> , <i>winsorizing</i>
<i>Boxplot fences (IQR)</i>	<i>Inner fence</i> ($1.5 \times IQR$) dan <i>outer fence</i> ($3 \times IQR$) untuk membedakan tingkat ekstremitas	Kategorisasi, <i>capping</i> , pembatasan ekstrem
<i>Chauvenet's Criterion</i>	Nilai dengan probabilitas sangat rendah dalam distribusi normal	Hapus nilai yang memenuhi kriteria probabilitas


<i>Winsorizing</i>	Mengganti nilai ekstrem dengan persentil tertentu, misalnya di bawah 5 % diganti nilai pada persentil ke-5	Batasi nilai ekstrem tanpa menghapus data
--------------------	--	---

Deskripsi pada Tabel 11 menggambarkan berbagai strategi yang digunakan untuk mengidentifikasi dan menangani *outlier*, masing-masing dengan ambang deteksi serta opsi penyesuaian yang khas. Informasi ini mempermudah proses pemilihan pendekatan yang sesuai dengan sifat data dan tujuan pengolahan. Teknik *Z-score* adalah salah satu yang paling sering digunakan ketika distribusi data relatif normal. Pendekatan ini menandai titik data sebagai *outlier* jika nilainya terlalu jauh dari rata-rata berdasarkan ukuran deviasi standar. Strategi ini sederhana dan efektif, tetapi menjadi kurang tepat ketika distribusi data sangat miring atau memiliki ekor panjang. Pada situasi di mana teknik ini relevan, penyesuaian dapat dilakukan dengan membatasi nilai ekstrem agar tetap dalam kisaran yang wajar atau menghapusnya jika berisiko mengganggu keakuratan hasil.

Pendekatan *IQR (Interquartile Range)* menawarkan ketahanan terhadap pengaruh nilai ekstrem karena menggunakan ukuran sebaran yang berbasis median. Ambang $1.5 \times \text{IQR}$ digunakan untuk mengidentifikasi *outlier* moderat, sedangkan ambang yang lebih besar dapat digunakan untuk menandai *outlier* ekstrem. Opsi penyesuaian biasanya berupa *clamping* yang menahan nilai pada batas tertentu atau *winsorizing* yang mengganti nilai ekstrem dengan nilai pada batas persentil yang ditentukan. Konsep *boxplot fences* masih berakar pada perhitungan IQR, tetapi memperkenalkan dua tingkat ambang, yakni *inner fence* dan *outer fence*. Hal ini membantu membedakan antara *outlier* ringan dan ekstrem, yang berguna dalam interpretasi visual

maupun pembuatan keputusan lanjutan. Pada tahap ini, penyesuaian bisa dilakukan secara bertingkat sesuai tingkat ekstremitasnya, mulai dari sekadar penandaan hingga pembatasan atau penghapusan nilai.

Chauvenet's Criterion menggunakan prinsip probabilistik untuk menentukan apakah suatu nilai layak dianggap *outlier*. Jika peluang kemunculannya dalam distribusi normal terlalu kecil, maka nilai tersebut dinilai tidak mewakili populasi yang wajar. Opsi penyesuaian umumnya berupa penghapusan nilai tersebut, terutama jika mempertahankannya akan menurunkan representativitas data. Sementara itu, *Winsorizing* adalah strategi yang tidak menghapus data, tetapi membatasi nilai ekstrem agar berada dalam kisaran yang ditentukan oleh persentil. Pendekatan ini menjaga jumlah observasi tetap sama, sehingga perhitungan statistik yang peka terhadap ukuran sampel tetap stabil. Keunggulan lain dari *winsorizing* adalah kemampuannya mengurangi pengaruh nilai ekstrem tanpa menghilangkan sepenuhnya informasi yang terkandung di dalamnya. Penyusunan Tabel 11 memberikan gambaran bahwa setiap teknik memiliki keunggulan dan keterbatasan. Pemilihan metode yang tepat akan dipengaruhi oleh sifat distribusi data, tujuan analisis, dan tingkat toleransi terhadap risiko bias akibat penghapusan atau pengubahan nilai. Pada data pasar modal misalnya, teknik *IQR* atau *winsorizing* sering dipilih karena data harga saham cenderung memiliki fluktuasi alami yang besar, sehingga menghapus terlalu banyak nilai bisa menghilangkan sinyal penting. Sebaliknya, pada data pengukuran sensor yang stabil, penggunaan *Z-score* atau *Chauvenet's Criterion* dapat lebih efektif.



Gambar 23. Sebaran Nilai Sebelum dan Sesudah Penyesuaian

Gambar ini memperlihatkan perbandingan sebaran nilai pada dua kondisi, yakni sebelum penyesuaian yang ditandai dengan warna merah (*before improvement*) dan sesudah penyesuaian yang ditandai dengan warna biru kehijauan (*after improvement*). Visualisasi berbentuk *histogram overlay* ini menempatkan kedua distribusi pada sumbu yang sama, sehingga perbedaan pola, pergeseran nilai, serta perubahan proporsi dapat diamati secara langsung. Sumbu horizontal menunjukkan rentang nilai dalam bentuk *frequency bins* dari 0 hingga 1, sedangkan sumbu vertikal menggambarkan frekuensi kemunculan data pada tiap interval. Distribusi awal tampak memiliki ketidakseimbangan, dengan frekuensi yang relatif rendah di sebagian besar rentang, namun menunjukkan puncak-puncak tertentu, terutama pada area mendekati

nilai 1. Warna merah yang mendominasi di titik-titik tersebut menunjukkan adanya konsentrasi nilai yang belum merata di seluruh rentang.

Setelah penyesuaian, pola distribusi mengalami perubahan yang terlihat jelas. Pada bagian rentang nilai rendah (sekitar 0 hingga 0,1), frekuensi nilai bertambah, ditandai dengan puncak berwarna biru kehijauan yang lebih menonjol dibandingkan kondisi awal. Perubahan ini mengindikasikan adanya peningkatan representasi data pada area yang sebelumnya kurang terisi. Pada rentang tengah (sekitar 0,4 hingga 0,6), distribusi sesudah penyesuaian memperlihatkan pemerataan yang lebih baik. Puncak-puncak merah yang sebelumnya dominan berkurang, digantikan oleh puncak biru kehijauan, yang menandakan redistribusi data ke area ini. Langkah ini biasanya dilakukan untuk mengisi kesenjangan distribusi dan mengurangi dominasi frekuensi di area tertentu.

Perbedaan yang paling menonjol terlihat pada nilai mendekati 1. Sebelum penyesuaian, terdapat lonjakan besar berwarna merah yang menandakan penumpukan signifikan pada ujung skala. Sesudah penyesuaian, meskipun puncak masih terlihat, warnanya kini bercampur dengan biru kehijauan, menunjukkan bahwa data di area tersebut telah mengalami pengurangan konsentrasi dan perbaikan distribusi. Perpaduan warna merah dan biru kehijauan di banyak titik menandakan bahwa proses penyesuaian bukanlah penghapusan total data pada rentang tertentu, melainkan penyesuaian proporsinya. Hal ini memberikan gambaran bahwa penyesuaian dilakukan secara selektif dan terukur, menjaga keberadaan nilai asli sembari mengoreksi ketidakseimbangan distribusi.

Kejelasan visual diperkuat oleh penggunaan dua warna kontras yang mudah dibedakan, serta keterangan legenda di bagian atas yang memberi penjelasan ringkas. Tata letak dan kalibrasi sumbu yang tepat membantu pembaca memahami frekuensi dan sebaran nilai secara kuantitatif, meskipun pesan utama dapat ditangkap secara intuitif hanya dari perbedaan warna dan bentuk histogram. Manfaat utama dari visual ini adalah kemampuannya menampilkan dampak nyata dari penyesuaian dalam satu pandangan. Pergeseran frekuensi, peningkatan pemerataan distribusi, dan pengurangan dominasi di titik tertentu dapat dilihat secara langsung, tanpa perlu penjabaran angka yang kompleks. Dengan demikian, gambar ini berfungsi sebagai alat evaluasi visual yang efektif untuk menilai keberhasilan langkah penyesuaian terhadap kualitas distribusi data. Perubahan yang tampak lebih seimbang setelah penyesuaian menunjukkan bahwa data kini memiliki representasi yang lebih proporsional di seluruh rentang nilai. Kondisi ini dapat membantu meningkatkan performa sistem atau model yang bergantung pada data tersebut. Namun, keseimbangan antara perubahan dan pelestarian karakteristik asli tetap menjadi pertimbangan penting. Jika perubahan terlalu drastis, keaslian distribusi bisa dipertanyakan; sebaliknya, jika perubahan moderat namun konsisten, maka hasilnya dapat dianggap berhasil.

Normalisasi dan standarisasi fitur

Normalisasi dan standarisasi merupakan tahap prapemrosesan penting dalam pengolahan data pasar saham, khususnya saat diterapkan pada model *deep learning*. Kedua teknik ini memastikan skala data yang

seragam sehingga setiap fitur berkontribusi secara seimbang terhadap pembelajaran. Dalam pasar yang dinamis, dengan rentang nilai antarfitur yang beragam, penerapan skala yang tepat mempercepat pelatihan model dan menjaga stabilitas perhitungan.

Normalisasi mengubah nilai fitur ke dalam rentang tertentu, misalnya 0 hingga 1 atau -1 hingga 1, tanpa mengubah bentuk distribusi asli. Langkah ini mencegah dominasi fitur berskala besar terhadap gradien perhitungan, sehingga algoritme optimisasi seperti *gradient descent* bekerja lebih efisien, mengurangi risiko *vanishing* atau *exploding gradients*, dan mempercepat konvergensi. Dampaknya sangat terasa pada arsitektur seperti LSTM dan CNN yang sensitif terhadap besar-kecilnya nilai input.

Standarisasi, di sisi lain, menyesuaikan data agar memiliki rata-rata nol dan deviasi standar satu. Hal ini menciptakan distribusi yang seimbang, membantu model memproses setiap fitur dengan bobot proporsional terhadap variasinya. Teknik ini bermanfaat ketika data mengandung *outliers* atau diharapkan menyerupai distribusi Gaussian, sehingga nilai ekstrem dapat diminimalkan tanpa kehilangan informasi penting. Pemilihan teknik bergantung pada karakteristik data dan kebutuhan model. Normalisasi cocok untuk data dengan batas nilai jelas atau yang memerlukan rentang tertentu untuk fungsi aktivasi tertentu. Standarisasi lebih sesuai bagi data dengan sebaran lebar dan tidak terbatas, karena membantu menjaga keseimbangan distribusi meski terdapat nilai ekstrem. Dalam praktiknya, kombinasi keduanya dapat digunakan secara strategis untuk mengoptimalkan kinerja model.

Teknik skala memengaruhi akurasi prediksi secara signifikan. Tanpa skala yang tepat, model dapat memberikan bobot berlebih pada

fitur hanya karena perbedaan skala, bukan relevansi. Ini berpotensi menimbulkan prediksi bias dan menurunkan keterbacaan hasil. Oleh sebab itu, penerapan normalisasi atau standarisasi tak hanya memperbaiki efisiensi komputasi tetapi juga meningkatkan keandalan prediksi.

Dalam pasar saham yang fluktuatif, teknik ini membantu model mengenali pola halus yang mungkin terabaikan jika perbedaan skala terlalu besar. Perubahan kecil pada indikator teknis dapat menjadi sinyal penting bila diolah dalam skala yang sebanding. Selain itu, penerapan skala mendukung stabilitas model terhadap data baru, menjaga konsistensi prediksi meskipun kondisi pasar berubah. Secara operasional, normalisasi dan standarisasi dilakukan setelah pembersihan data, termasuk pengisian nilai hilang dan penyesuaian *outliers*. Urutan ini memastikan data yang diproses telah bersih dan siap digunakan. Fungsi atau algoritme skala biasanya diintegrasikan ke dalam alur pemrosesan agar proses berlangsung otomatis dan konsisten di setiap siklus pelatihan. Dengan penerapan yang tepat, model prediksi pasar saham dapat memanfaatkan setiap fitur secara optimal. Pendekatan ini mempercepat pembelajaran, menstabilkan perhitungan, dan menjaga distribusi tetap seimbang, menjadi salah satu faktor kunci membangun sistem prediksi yang andal di tengah volatilitas pasar.

Tabel 12. Perbandingan *Min–Max Scaling* dan *Z-Score Normalization* pada Data Harga

Aspek	Min–Max Scaling	Z-Score Normalization
Rentang Hasil	Mengubah nilai ke rentang tertentu, biasanya 0–1 atau –1–1	Tidak memiliki batas tetap; bergantung pada distribusi data

Sensitivitas terhadap <i>outlier</i>	Sangat peka; nilai ekstrem memperlebar rentang	Lebih tahan; nilai ekstrem diimbangi oleh variasi data
Pelestarian Distribusi	Bentuk distribusi asli dipertahankan, meski dalam skala menyusut	Distribusi tetap sama, namun skala distandarisasi
Interpretabilitas	Lebih mudah dipahami karena berada pada rentang umum	Disajikan dalam satuan <i>standar deviasi</i> , memerlukan pengetahuan statistik
Kebutuhan Data	Hanya membutuhkan nilai minimum dan maksimum	Membutuhkan nilai rata-rata dan <i>standar deviasi</i>
Kecocokan Penggunaan	Visualisasi dan model dengan batas input tertentu	Model statistik atau data dengan <i>outlier</i> yang signifikan


Tabel ini merangkum dua teknik normalisasi yang umum digunakan pada data harga, yaitu *min-max scaling* dan *Z-score normalization*. Keduanya merupakan bagian dari proses *feature scaling* yang bertujuan membuat variabel berada pada skala yang sebanding agar dapat diolah lebih efektif oleh algoritma atau dipresentasikan secara visual. Pada *min-max scaling*, seluruh nilai diubah secara proporsional agar berada dalam rentang tertentu—biasanya 0 hingga 1. Teknik ini mempertahankan bentuk distribusi data, tetapi menyesuaikan skala sehingga semua nilai mudah dibandingkan secara visual maupun numerik. Kelebihan utamanya terletak pada kemudahan interpretasi: nilai 0 menandakan titik terendah, sedangkan nilai 1 menandakan titik tertinggi. Meski begitu, teknik ini memiliki kelemahan nyata pada data dengan *outlier* besar, karena satu nilai ekstrem dapat mengubah rentang dan membuat nilai lainnya terkompres di area yang sempit.

Sebaliknya, *Z-score normalization* mengubah nilai menjadi ukuran relatif terhadap rata-rata, dinyatakan dalam satuan *standar deviasi*.

Teknik ini mempertahankan bentuk distribusi asli dan memberikan daya tahan yang lebih baik terhadap *outlier*, karena pengaruh nilai ekstrem akan disebar ke seluruh skala. Hanya saja, interpretasi hasilnya memerlukan pemahaman statistik, nilai positif berarti berada di atas rata-rata, dan nilai negatif berada di bawah rata-rata. Perbedaan kebutuhan data juga menjadi pertimbangan. *Min-max scaling* hanya memerlukan nilai minimum dan maksimum, sehingga cepat dan mudah dilakukan. Sebaliknya, *Z-score normalization* memerlukan rata-rata dan *standar deviasi*, menjadikannya sedikit lebih kompleks. Perbedaan ini memengaruhi waktu komputasi, meskipun untuk dataset modern, perbedaan tersebut biasanya tidak signifikan.

Pemilihan teknik bergantung pada tujuan. Untuk visualisasi harga saham atau data keuangan yang perlu dipresentasikan ke audiens luas, *min-max scaling* sering menjadi pilihan karena lebih intuitif. Namun, untuk pemodelan prediktif atau statistik, terutama jika data mengandung fluktuasi besar atau nilai ekstrem, *Z-score normalization* lebih tepat karena menjaga proporsionalitas relatif antar nilai. Ada pula skenario di mana kedua teknik digunakan bersama. Misalnya, sebuah model dapat menstandarisasi data menggunakan *Z-score* pada tahap perhitungan internal, kemudian mengubah hasilnya menjadi skala 0–1 menggunakan *min-max* agar lebih mudah dibaca saat disajikan ke publik. Pendekatan ganda ini memanfaatkan kekuatan masing-masing teknik tanpa mengorbankan kejelasan komunikasi. Jika diaplikasikan pada data harga, efek kedua teknik ini terlihat jelas. Dengan *min-max scaling*, pergerakan harga harian dapat ditampilkan secara terukur dalam rentang seragam, memudahkan perbandingan antar periode. Sedangkan dengan *Z-score normalization*, kita dapat langsung mengidentifikasi periode harga yang

secara signifikan lebih tinggi atau lebih rendah dibanding tren rata-rata, yang berguna untuk mendeteksi anomali atau mengidentifikasi pola jangka panjang.



Gambar 24. Kurva Distribusi dan Plot Sebelum dan Sesudah Normalisasi

Gambar ini menampilkan perbandingan kondisi data sebelum dan sesudah proses normalisasi, yang diilustrasikan melalui dua jenis visualisasi. Bagian atas terdiri atas *density plot* yang menggambarkan distribusi intensitas dua kanal data yang dibedakan dengan warna merah dan hijau. Bagian bawah memuat *scatter plot* hubungan antara nilai A dan M pada kedua kondisi. Pada *density plot* sebelah kiri, yang merepresentasikan kondisi sebelum normalisasi, kedua kurva distribusi

tampak berbeda secara mencolok. Kurva merah menunjukkan puncak yang tinggi dan sempit, sedangkan kurva hijau memiliki puncak lebih rendah dengan sebaran yang sedikit lebih lebar. Perbedaan posisi dan bentuk puncak mengindikasikan ketidaksejajaran distribusi antara kedua kanal, yang dapat mengakibatkan bias saat data digunakan untuk perbandingan atau penghitungan turunan nilai.

Density plot sebelah kanan memperlihatkan hasil setelah normalisasi. Kedua kurva, merah dan hijau, hampir sepenuhnya tumpang tindih, menandakan bahwa distribusi kanal telah disejajarkan. Proses normalisasi telah mengoreksi perbedaan distribusi awal sehingga kedua kanal berada pada skala yang setara. Keselarasan ini penting untuk memastikan bahwa perbedaan nilai yang muncul pada tahap analisis selanjutnya mencerminkan variasi yang relevan, bukan artefak akibat perbedaan teknis. Bagian bawah gambar memperlihatkan *scatter plot* antara nilai A (sumbu horizontal) dan M (sumbu vertikal). Plot sebelah kiri, sebelum normalisasi, menampilkan pola sebaran yang kurang simetris terhadap garis $M = 0$. Titik-titik data menunjukkan variasi yang lebar pada beberapa rentang nilai A, dengan kepadatan yang tidak merata di sekitar garis tengah. Keadaan ini menunjukkan adanya bias sistematis yang mungkin terkait dengan perbedaan distribusi kanal.

Plot di sebelah kanan, setelah normalisasi, menunjukkan distribusi titik yang lebih terpusat di sekitar garis $M = 0$. Sebaran data terlihat lebih simetris, dengan variasi M yang lebih terkontrol di seluruh rentang nilai A. Kepadatan titik di sekitar pusat distribusi lebih merata, mencerminkan bahwa perbedaan antara kanal telah direduksi dan hubungan A–M menjadi lebih seimbang. Kedua jenis visualisasi ini saling melengkapi. *Density plot* memberikan gambaran langsung tentang perubahan bentuk

dan posisi distribusi kanal, sedangkan *scatter plot* menunjukkan dampak perbaikan tersebut terhadap hubungan antarvariabel yang dihitung dari data kanal. Dengan melihat keduanya, dapat dipahami bahwa normalisasi berfungsi ganda: menyelaraskan distribusi dan memperbaiki simetri hubungan, sehingga kualitas data meningkat secara keseluruhan.

Penggunaan warna yang kontras pada *density plot* memudahkan identifikasi kanal, baik sebelum maupun sesudah normalisasi. Sementara itu, *scatter plot* menggunakan gradasi warna biru untuk menunjukkan kepadatan titik, yang membantu mengidentifikasi area konsentrasi data tertinggi. Kombinasi ini tidak hanya memperjelas perubahan yang terjadi, tetapi juga membuat informasi lebih mudah diinterpretasikan secara visual. Gambar ini mengilustrasikan bahwa normalisasi adalah tahap penting untuk menyiapkan data agar siap digunakan pada tahap analisis berikutnya. Penyelarasan distribusi antar kanal mengurangi kemungkinan bias teknis, dan perbaikan simetri hubungan antarvariabel memberikan dasar yang lebih stabil untuk interpretasi hasil.

Teknik reduction

Data harga saham sering kali dipenuhi dengan gangguan (*noise*) yang muncul akibat volatilitas pasar, pengaruh mikrostruktur perdagangan, serta peristiwa eksternal yang tidak terduga. Situasi ini membuat pola inti kerap tertutup oleh fluktuasi acak yang tidak mewakili pergerakan fundamental. Untuk mengatasi hal ini, digunakan berbagai teknik *reduction* yang bertujuan menekan gangguan tanpa menghilangkan sinyal utama yang menjadi dasar pengambilan keputusan.

Salah satu pendekatan yang banyak digunakan adalah perataan (*smoothing*), yang meliputi *moving averages*, *Gaussian filters*, dan varian seperti *modified Hodrick–Prescott filter*. Perataan membantu meredam fluktuasi berfrekuensi tinggi pada rangkaian waktu harga saham sehingga tren utama dan pola siklus lebih mudah dikenali. Dengan mengurangi komponen volatil yang bersifat sementara, langkah ini membuat model prediksi maupun pengamatan manual lebih fokus pada pergerakan yang berkesinambungan. Sebagai contoh, *modified Hodrick–Prescott filter* efektif memisahkan tren jangka panjang dari gangguan jangka pendek sehingga arah pergerakan harga dapat dikenali dengan lebih tepat. *Gaussian filter* memberikan manfaat dengan menekan gangguan acak sambil mempertahankan bentuk pola yang penting. Dengan menonjolkan kelancaran kurva dan meredam perubahan mendadak yang bersifat acak, filter ini menampilkan karakteristik intrinsik harga saham secara lebih jelas. Dampaknya adalah peningkatan keterbacaan pola, yang dapat memperkuat proses pengambilan keputusan strategis.


Selain perataan, *wavelet transform* menjadi teknik *reduction* yang sangat bernilai karena mampu melakukan analisis pada berbagai skala (*multi-resolution analysis*). Proses ini memecah data harga saham menjadi koefisien-koefisien pada berbagai frekuensi, sehingga komponen *noise*—sering kali berupa koefisien beramplitudo kecil—dapat ditekan melalui *thresholding*. Keunggulannya terletak pada kemampuannya mempertahankan elemen sinyal yang signifikan, termasuk perubahan mendadak atau diskontinuitas, sambil tetap mengurangi gangguan pada berbagai tingkat resolusi. Jika digunakan bersama model prediksi berbasis *deep learning* seperti LSTM atau CNN, *wavelet transform* tidak hanya membersihkan gangguan, tetapi juga memisahkan komponen data yang

paling informatif. Hasilnya, prediksi menjadi lebih tepat karena model bekerja dengan representasi data yang telah dimurnikan dari elemen yang mengaburkan pola inti. Strategi ini terbukti efektif pada pasar yang dinamis, di mana kemampuan menangkap sinyal murni menjadi faktor pembeda penting.

Pemilihan teknik *reduction* yang sesuai dipengaruhi oleh sifat data dan tujuan pemrosesan. Untuk data dengan fluktuasi acak yang dominan, perataan sederhana kerap memadai untuk memperjelas tren. Namun, bila diperlukan pemisahan sinyal pada berbagai skala, *wavelet transform* menawarkan keunggulan tersendiri. Dalam praktik, kedua pendekatan ini sering dipadukan: perataan digunakan untuk menghapus variasi jangka sangat pendek, sedangkan *wavelet transform* memetakan struktur sinyal secara lebih mendalam. Keberhasilan penerapan langkah ini terlihat dari kemampuannya menjaga integritas informasi penting sambil menghilangkan komponen yang kurang relevan. Hasilnya, baik analisis maupun sistem otomatis dapat mengambil keputusan dengan landasan yang lebih kuat, meminimalkan risiko kesalahan akibat interpretasi terhadap *noise* pasar.

Dalam rangkaian pemrosesan data pasar saham, tahap *reduction* umumnya dilakukan setelah pembersihan data termasuk pengisian nilai yang hilang dan penyesuaian *outliers*—dan sebelum normalisasi atau standarisasi. Urutan ini memastikan bahwa pengaturan skala data dilakukan pada sinyal yang telah dimurnikan sehingga tahap selanjutnya dapat bekerja secara optimal. Dengan mengombinasikan teknik perataan dan transformasi multi-resolusi, pengolahan data pasar saham dapat difokuskan pada pengungkapan pola inti yang relevan terhadap dinamika pasar. Pendekatan ini membuat sistem prediksi bekerja lebih efisien,

memanfaatkan informasi murni, dan tetap tanggap terhadap perubahan signifikan tanpa terpengaruh oleh fluktuasi acak yang tidak memberikan nilai tambah.



Gambar 25. Perbandingan Sinyal Asli dan Sinyal Setelah Proses *Filtering*

Gambar 25 menampilkan ilustrasi perbedaan yang jelas antara sinyal asli (*raw signal*) dan sinyal yang telah melalui proses penyaringan (*filtered signal*). Visual ini terdiri atas tiga bagian utama: grafik sinyal asli di bagian atas, diagram rangkaian penyaring di bagian tengah, dan grafik sinyal hasil penyaringan pada bagian bawah. Grafik pada bagian atas menunjukkan *raw signal* dalam bentuk tegangan terhadap waktu. Sinyal ini memperlihatkan gelombang rapat dengan puncak dan lembah yang acak, serta amplitudo yang bervariasi di sekitar nilai tengah. Karakteristik ini mencerminkan sifat data mentah yang sering kali mengandung *noise* atau gangguan. Sumber *noise* dapat berasal dari kondisi lingkungan, keterbatasan instrumen pengukuran, maupun sifat alami sistem yang menghasilkan sinyal. Kehadiran gangguan tersebut membuat sinyal sulit

untuk digunakan secara langsung, terutama jika tujuannya adalah menyoroti pola atau komponen periodik yang lebih halus.

Bagian tengah berisi diagram rangkaian sederhana yang terdiri dari resistor (R) dan kapasitor (C) yang disusun secara seri, disertai simbol sumber tegangan bolak-balik (*AC voltage source*) sebagai masukan, dilabeli $V_{in}(t)$. Rangkaian ini menggambarkan prinsip kerja penyaring pasif, seperti *low-pass filter*, yang berfungsi mengurangi komponen frekuensi tinggi sehingga sinyal keluarannya lebih halus dan bebas dari sebagian besar gangguan. Grafik pada bagian bawah memperlihatkan *filtered signal*, yaitu sinyal yang dihasilkan setelah melewati rangkaian tersebut. Bentuk gelombangnya tampak jauh lebih teratur, dengan fluktuasi cepat yang telah berkurang secara signifikan. Amplitudo yang konsisten serta pola yang lebih bersih membuat sinyal ini lebih mudah dibaca dan diinterpretasikan. Proses ini menegaskan peran penyaring dalam memisahkan komponen utama yang penting dari gangguan yang tidak diinginkan.

Penggunaan warna memperjelas perbedaan kondisi sebelum dan sesudah penyaringan. Pada *raw signal*, latar berwarna merah muda mengesankan sifat bising dan tidak stabil. Sebaliknya, *filtered signal* ditampilkan dengan warna biru lembut yang memberi kesan bersih dan stabil. Perubahan ini secara visual menegaskan transformasi dari data mentah menuju data yang telah diperbaiki kualitasnya. Diagram rangkaian di tengah bukan hanya elemen pelengkap, tetapi juga menghubungkan konsep sinyal dengan proses teknis yang mengubahnya. Penempatannya di antara grafik masukan dan keluaran memberi gambaran bahwa sinyal mentah masuk ke dalam rangkaian, lalu diolah hingga menjadi sinyal yang lebih rapi.

Visual ini menunjukkan bahwa meskipun sinyal asli memuat informasi yang sama, *noise* dapat menyamarkan detail penting. Dengan proses penyaringan yang tepat, gangguan tersebut dapat diminimalkan tanpa menghilangkan inti informasi yang diperlukan. Hasil seperti ini bermanfaat dalam berbagai bidang, mulai dari komunikasi elektronik, pemrosesan data ilmiah, hingga sistem pemantauan industri, di mana kejelasan sinyal memegang peranan penting. Perbandingan dua grafik tersebut menegaskan bahwa perbedaan utama tidak hanya terletak pada tampilan visual, tetapi juga pada kualitas informasi yang dapat diambil. Sinyal mentah kerap membutuhkan pengolahan lanjutan sebelum dapat digunakan, sedangkan sinyal yang telah difilter langsung memberikan gambaran yang lebih jelas dan representatif.

Bab 7. Rekayasa Fitur untuk Meningkatkan Kinerja Model

Pemilihan indikator teknikal

Pemilihan indikator teknikal yang tepat dalam pemodelan pasar saham memegang peran penting untuk memastikan model bekerja efisien dan mampu menghasilkan prediksi yang dapat diandalkan. Indikator yang dipilih tidak semata karena popularitasnya di kalangan praktisi, melainkan harus memiliki dasar yang kuat dalam merepresentasikan dinamika pasar, menunjukkan kekuatan prediktif yang konsisten, serta memberikan nilai praktis bagi pengambilan keputusan. Dengan demikian, model terhindar dari kelebihan fitur yang justru dapat mengurangi kinerja dan meningkatkan risiko *overfitting*. Aspek yang perlu diperhatikan dalam memilih indikator meliputi landasan teoretis yang jelas, bukti kekuatan prediktif yang teruji, kemampuan bertahan di berbagai kondisi pasar, dan efektivitas dalam menekan *noise* sekaligus mempertegas sinyal relevan. Indikator yang baik akan merefleksikan elemen penting seperti tren, momentum, dan volatilitas. Kinerja indikator dapat dinilai melalui hubungan statistiknya dengan pergerakan harga di masa depan, konsistensi hasil di berbagai jangka waktu, serta kontribusi tambahannya ketika dipadukan dengan indikator lain dalam model prediksi terpadu.


Contoh indikator tren yang sering digunakan adalah *moving averages* dan *moving average convergence divergence* (MACD), yang efektif mengekstraksi pola pergerakan harga secara keseluruhan. Sementara itu, indikator momentum seperti *relative strength index* (RSI)

berguna untuk mengidentifikasi kondisi *overbought* atau *oversold*. Kedua jenis indikator ini dapat dilengkapi dengan indikator volume atau volatilitas untuk meningkatkan akurasi prediksi. Pendekatan gabungan semacam ini menjadi semakin bernilai ketika diterapkan pada model *machine learning* seperti *support vector machines* atau arsitektur *long short-term memory* (LSTM), yang mengandalkan interaksi antarfitur guna memaksimalkan kinerja. Pemilihan indikator sebaiknya mempertimbangkan tidak hanya performa individu, tetapi juga sinergi yang muncul saat digunakan bersama. Indikator yang saling melengkapi akan memberikan gambaran pasar yang lebih menyeluruh, sedangkan indikator yang tumpang tindih cenderung menambah kompleksitas tanpa memberikan wawasan baru.

Proses penyaringan indikator dapat dilakukan melalui algoritma seleksi fitur seperti *gain ratio*, fungsi berbasis *Relief*, *L1 regularized logistic regression*, dan pendekatan *wrapper* yang menilai indikator berdasarkan dampaknya terhadap kinerja model. Teknik-teknik ini membantu mengidentifikasi indikator dengan rasio sinyal terhadap *noise* yang tinggi, hubungan statistik yang konsisten, serta kemampuan meningkatkan akurasi tanpa beban komputasi berlebihan. Peningkatan lebih lanjut dapat dicapai menggunakan algoritma berbasis *heap* yang efisien untuk menelusuri ruang kombinasi indikator dan menemukan set fitur optimal. Pendekatan *embedded*, yang mengintegrasikan seleksi fitur langsung ke dalam algoritma pembelajaran, juga bermanfaat untuk menghindari indikator redundan sehingga hanya tersisa fitur dengan kontribusi unik dan signifikan terhadap prediksi.

Melalui strategi ini, proses pemilihan indikator teknikal menjadi lebih terukur dan terarah. Tujuan akhirnya adalah membentuk model

prediksi yang ringkas, terhindar dari *overfitting*, dan mampu menangkap dinamika pasar secara akurat. Dalam lanskap pasar yang kompetitif dan penuh ketidakpastian, kemampuan menyaring indikator dengan keseimbangan antara kekuatan prediktif, manfaat praktis, dan efisiensi komputasi menjadi keunggulan yang membedakan.



Gambar 26. Grafik Mingguan IHSG dengan Overlay Indikator Teknis

Gambar ini menampilkan visualisasi *Indeks Harga Saham Gabungan* (IHSG) dalam format *candlestick* mingguan, dilengkapi dengan lapisan (*overlay*) indikator teknikal dan osilator untuk memberikan pandangan yang lebih menyeluruh terhadap dinamika pergerakan harga. Setiap batang *candlestick* merepresentasikan rangkuman pergerakan harga selama satu minggu, termasuk harga pembukaan, tertinggi, terendah, dan penutupan. Tiga garis *Moving Average* (MA) dengan periode berbeda ditampilkan pada grafik utama, masing-masing MA 5 minggu (merah), MA 20 minggu (hijau), dan MA 50 minggu (biru). Garis-garis ini berfungsi mengilustrasikan tren harga pada skala waktu berbeda, mulai dari tren jangka pendek hingga jangka panjang. Interaksi antar-

garis MA, seperti persilangan ke atas atau ke bawah, sering dimanfaatkan untuk mengidentifikasi potensi perubahan arah tren.

Lapisan tambahan berupa level *Fibonacci retracement* dan *extension* divisualisasikan dengan garis horizontal biru. Level-level ini membantu memetakan potensi area *support* dan *resistance* berdasarkan pergerakan harga sebelumnya, yang kerap menjadi perhatian pelaku pasar dalam memprediksi pembalikan atau kelanjutan tren. Histogram volume perdagangan mingguan terletak di bagian bawah grafik harga. Warna hijau menunjukkan volume lebih dominan pada minggu kenaikan harga, sedangkan warna merah pada minggu penurunan. Intensitas volume dapat menjadi petunjuk penting terkait kekuatan atau lemahnya pergerakan harga pada periode tertentu.

Panel kedua menampilkan indikator *Moving Average Convergence Divergence* (MACD), yang terdiri atas dua garis utama dan histogram. MACD membantu mengukur kekuatan tren dan momentum pasar. Histogram positif umumnya mencerminkan dominasi tren naik, sementara histogram negatif mengindikasikan tren turun yang lebih kuat. Perpotongan antara garis MACD dan garis sinyal juga sering dibaca sebagai indikasi awal perubahan momentum. Panel ketiga memuat *Stochastic Oscillator*, indikator yang dirancang untuk mengidentifikasi kondisi jenuh beli (*overbought*) dan jenuh jual (*oversold*). Dua garis dalam indikator ini, %K (biru) dan %D (merah), bergerak dalam rentang 0–100. Posisi di atas batas atas menandakan potensi jenuh beli, sedangkan di bawah batas bawah menunjukkan potensi jenuh jual. Kombinasi antara *overlay* pada grafik harga, indikator momentum, serta volume perdagangan menciptakan kerangka visual yang memungkinkan

pembaca memahami tren, kekuatan pergerakan, serta potensi area pembalikan harga secara bersamaan.

Moving average untuk menangkap tren

Moving average (MA) adalah salah satu instrumen penting dalam *technical analysis* yang digunakan untuk menghaluskan fluktuasi harga saham dan memperjelas arah tren. Prinsipnya sederhana, yaitu menghitung rata-rata harga dalam periode tertentu sehingga pergerakan acak bersifat sementara dapat diredam. Dengan cara ini, perhatian dapat diarahkan pada kecenderungan harga yang lebih berkelanjutan dan mendasar. Proses penghalusan ini membantu membedakan antara tren yang benar-benar terbentuk dengan pergerakan sesaat yang muncul akibat *market noise*. Penerapan MA dapat disesuaikan dengan strategi serta tujuan para pelaku pasar. Untuk mereka yang berfokus pada *short-term trading*, periode antara 5 hingga 20 hari sering menjadi pilihan karena mampu menangkap perubahan harga dengan cepat dan memberi sinyal yang relevan untuk keputusan jangka pendek. Sementara itu, investor jangka panjang cenderung memilih periode seperti 50, 100, atau bahkan 200 hari agar memperoleh gambaran tren yang lebih stabil dan mengurangi efek fluktuasi kecil. Panjang periode memengaruhi tingkat sensitivitas: periode pendek lebih cepat merespons perubahan harga, sedangkan periode panjang memberikan tampilan tren yang lebih mulus dan cenderung lebih andal untuk mengenali arah yang bersifat fundamental.

Salah satu pendekatan populer adalah strategi *crossover* yang melibatkan dua MA dengan periode berbeda. Ketika MA jangka pendek

melintas naik di atas MA jangka panjang, hal ini sering dimaknai sebagai sinyal beli yang menunjukkan potensi tren naik (*bullish*). Sebaliknya, jika MA jangka pendek menurun melewati MA jangka panjang, sinyal jual dapat muncul, mengindikasikan kemungkinan tren turun (*bearish*). Strategi ini didasari pemahaman bahwa perubahan momentum sering kali menjadi pendahulu pergeseran harga yang signifikan, sehingga memberi peluang untuk mengambil langkah lebih awal. Dalam perkembangan terkini, MA tidak hanya dimanfaatkan secara konvensional tetapi juga terintegrasi dalam sistem yang lebih modern, termasuk model *machine learning*. Penggabungan ini memungkinkan pemrosesan berbagai indikator secara bersamaan sehingga prediksi pergerakan harga menjadi lebih akurat. MA dapat berperan mendeteksi tren, sekaligus melengkapi analisis teknikal maupun fundamental untuk menghasilkan pendekatan yang lebih menyeluruh.

Pemilihan periode yang tepat sangat menentukan keberhasilan penggunaannya. Kondisi pasar, tingkat volatilitas aset, dan tujuan investasi perlu menjadi pertimbangan utama. Pada pasar yang bergerak cepat dan bergejolak, MA berperiode pendek dapat memberikan sinyal lebih dini meski memiliki risiko menghasilkan *false signals*. Sebaliknya, pada kondisi yang stabil, MA berperiode panjang lebih tepat digunakan agar tidak terjebak pada reaksi berlebihan terhadap fluktuasi kecil. Selain periode, bentuk MA juga memengaruhi hasil. *Simple Moving Average* (SMA) memberikan bobot yang sama pada setiap harga dalam periode, sedangkan *Exponential Moving Average* (EMA) menitikberatkan bobot lebih besar pada harga terkini sehingga lebih peka terhadap perubahan. Pemilihan antara SMA atau EMA biasanya menyesuaikan dengan kebutuhan strategi—EMA cocok untuk pasar yang bergerak cepat,

sementara SMA memberikan kestabilan lebih dalam melihat tren jangka panjang.

Penggunaan MA dalam sistem prediksi modern memerlukan pemahaman hubungan dinamis antarindikator. Sebagai contoh, pada portofolio yang diuji melalui *backtesting*, MA dapat menjadi filter untuk memvalidasi sinyal dari indikator lain seperti *MACD* atau *stochastic oscillator*. Hal ini membuat keputusan lebih terukur dan berbasis pada data historis yang terverifikasi. MA juga bermanfaat dalam pengembangan fitur (*feature engineering*) pada model prediktif. Nilai MA, jarak harga terhadap MA, dan interaksi antar-MA dari periode berbeda dapat menjadi variabel penting yang membantu model mengenali pola tren maupun titik pembalikan secara otomatis. Dengan demikian, MA tidak hanya berfungsi sebagai panduan visual, tetapi juga sebagai komponen perhitungan yang dapat meningkatkan kinerja model.

Agar penggunaannya optimal, diperlukan pemahaman mendalam mengenai karakteristik instrumen dan perilaku harga. Faktor seperti sektor, tingkat likuiditas, dan sentimen pasar dapat memengaruhi efektivitas periode tertentu. Oleh sebab itu, pengujian historis menjadi langkah penting sebelum mengimplementasikan strategi MA dalam perdagangan nyata. Dengan kemampuannya menghaluskan pergerakan harga dan memberi sinyal perubahan tren melalui *crossover*, MA tetap menjadi salah satu alat utama di pasar keuangan. Integrasinya dengan teknologi prediksi modern memperluas manfaatnya, baik sebagai indikator visual maupun sebagai variabel prediktif yang mendukung pengambilan keputusan investasi yang lebih tepat.



Gambar 27. Contoh *Crossover* pada Indikator *MACD* di IHSX

Gambar ini memperlihatkan pergerakan harian Indeks Harga Saham Gabungan (*IHSX*) yang dilengkapi dengan indikator *Moving Average Convergence Divergence* (*MACD*). Indikator ini digunakan untuk menggambarkan dinamika perubahan momentum harga dengan membandingkan dua garis utama, yaitu *MACD line* dan *signal line*. Pada visual tersebut, terdapat dua peristiwa penting yang ditandai sebagai *crossover*: *Golden Cross* dan *Death Cross*, yang masing-masing diberi penanda berbentuk lingkaran dengan keterangan arah panah. Bagian atas grafik menampilkan pergerakan harga *IHSX* dalam format *candlestick chart*, memberikan gambaran visual mengenai pembukaan, penutupan, harga tertinggi, dan terendah setiap periode perdagangan. Periode yang ditampilkan menunjukkan transisi harga dari akhir tahun sebelumnya hingga pertengahan tahun berjalan, memperlihatkan fase tren naik, koreksi, dan pergerakan mendatar (*sideways*).

Panel bawah berisi indikator *MACD*. Garis berwarna biru menggambarkan *MACD line*, sedangkan garis merah adalah *signal line*.

Di latar belakangnya, histogram menunjukkan selisih kedua garis ini, dengan warna hijau ketika *MACD line* berada di atas *signal line*, dan warna merah ketika berada di bawahnya. Peristiwa *Golden Cross* terlihat pada awal Maret, ketika *MACD line* menembus *signal line* dari bawah ke atas. Sinyal ini sering dipandang sebagai indikasi awal momentum positif dan potensi kenaikan harga. Sebaliknya, *Death Cross* muncul pada awal Mei saat *MACD line* menembus *signal line* dari atas ke bawah, mengindikasikan potensi pelemahan tren atau awal pergerakan menurun. Visualisasi ini memberi wawasan bagi pelaku pasar untuk mengidentifikasi peluang berdasarkan sinyal teknikal. *Golden Cross* biasanya menjadi pemicu bagi sebagian pelaku pasar untuk melakukan pembelian pada awal tren naik, sedangkan *Death Cross* dapat memicu aksi jual atau *profit taking* untuk mengamankan keuntungan.

Selain mengilustrasikan sinyal beli dan jual, gambar ini juga mencerminkan tingkat volatilitas. Pergantian warna histogram dari hijau ke merah atau sebaliknya menunjukkan perubahan dominasi antara kekuatan beli dan jual. Fluktuasi yang tajam pada panjang batang histogram sering mengisyaratkan percepatan momentum, yang dapat menjadi sinyal pergerakan signifikan berikutnya. Meski *crossover* pada *MACD* cukup populer, banyak praktisi menggabungkannya dengan indikator tambahan atau pola harga tertentu untuk memperoleh konfirmasi lebih kuat. Penggunaan *MACD* dalam grafik *IHSG* membantu memahami arah tren jangka menengah sekaligus mengukur kekuatan pergerakan harga, sehingga bermanfaat bagi berbagai kalangan, baik investor ritel maupun institusional. Gambar ini menekankan pentingnya interpretasi yang disiplin. Sinyal yang dihasilkan dapat menjadi peluang atau jebakan, tergantung bagaimana pelaku pasar mengelola risikonya.

Pembuatan fitur lag untuk Historis

Fitur *lag* adalah elemen penting dalam pengolahan data *time series* karena membawa informasi dari periode sebelumnya ke dalam masukan model. Dengan menghadirkan nilai-nilai historis dari suatu variabel, model memperoleh kemampuan untuk mengenali pola berulang dan arah pergerakan yang berkesinambungan. Prinsipnya, kondisi masa lalu sering memengaruhi keadaan saat ini maupun yang akan datang, sehingga tercipta *memory effect* yang memperkaya proses pemodelan. Dalam praktik, pembuatan fitur *lag* dilakukan dengan menggeser nilai variabel ke belakang untuk jangka waktu tertentu. Sebagai contoh, harga penutupan saham pada hari ini dapat dipasangkan dengan harga penutupan satu hari sebelumnya (*lag 1*), dua hari sebelumnya (*lag 2*), dan seterusnya. Pendekatan ini membantu model mengungkap keterkaitan temporal yang mungkin tidak terlihat jika hanya mempertimbangkan nilai saat ini.


Penggunaan beberapa *lag* secara bersamaan memberikan cakupan informasi historis yang lebih luas. Misalnya, kombinasi *lag 1*, *lag 5*, dan *lag 10* memungkinkan model menangkap dinamika jangka pendek, menengah, dan panjang dalam satu kerangka prediksi. Hal ini mencerminkan realitas pasar keuangan yang memiliki perilaku berbeda pada tiap rentang waktu. Penentuan jumlah dan jarak *lag* perlu disesuaikan dengan karakteristik data dan tujuan prediksi. Pasar yang bergerak cepat lebih sesuai menggunakan *lag* pendek karena dapat memberikan sinyal responsif, sementara aset dengan harga relatif stabil akan lebih diuntungkan dari *lag* yang lebih panjang untuk menampilkan tren umum. Selain jumlah *lag*, langkah standarisasi atau normalisasi nilainya penting agar perbedaan skala tidak mengganggu pembelajaran model. Penyesuaian ini dapat berupa pengaturan terhadap rata-rata dan deviasi standar atau penerapan *min-max scaling*, sehingga setiap fitur memberikan kontribusi proporsional.

Fitur *lag* sering dikombinasikan dengan indikator teknikal seperti *moving averages*, *relative strength index* (RSI), atau *momentum*. Integrasi ini menambah kekayaan informasi, di mana *moving average* berperan menghaluskan fluktuasi dan menonjolkan tren, sedangkan *lag*

mempertahankan rincian dinamika harga pada titik tertentu. Sinergi keduanya menghadirkan perspektif yang lebih lengkap terhadap pergerakan pasar.

Dalam model *machine learning* maupun *deep learning* untuk *time series*, fitur *lag* tetap memiliki nilai penting meski arsitektur seperti *Long Short-Term Memory* (LSTM) atau *Gated Recurrent Unit* (GRU) telah dirancang untuk mengingat informasi historis. Pemberian *lag* eksplisit dapat memperkuat pengenalan pola musiman atau tren periodik, terutama pada data dengan sifat musiman yang kuat. Namun, penggunaan *lag* berlebihan tanpa seleksi yang tepat dapat meningkatkan kompleksitas dan risiko *overfitting*. Oleh karena itu, pemilihan *lag* yang relevan menjadi bagian esensial, dengan dukungan teknik seleksi fitur seperti *Recursive Feature Elimination* (RFE) atau pengukuran *feature importance* pada model berbasis pohon keputusan.

Dalam penerapan praktis, *lag* dapat diolah menjadi variabel turunan, seperti selisih atau rasio antara nilai saat ini dan nilai *lag* tertentu. Variabel ini mampu mengungkap perubahan relatif dan tingkat pertumbuhan yang sering menjadi sinyal penting dalam pengambilan keputusan. Kekuatan fitur *lag* terletak pada kemampuannya memadukan memori historis dengan data terkini, sehingga model lebih adaptif terhadap perubahan kondisi. Dengan pemilihan *lag* yang sesuai, penerapan normalisasi yang tepat, serta integrasi bersama indikator teknikal lain, fitur ini menjadi salah satu pilar utama dalam membangun model prediktif yang andal.



Gambar 28. Skema *Sliding Window* pada Data Perdagangan IHSG

Gambar 28 menampilkan ilustrasi *sliding window* yang digunakan untuk memproses data perdagangan IHSG dalam kurun waktu lima tahun. Konsep ini membagi deret waktu panjang menjadi potongan-potongan data berurutan dengan ukuran jendela tetap, yang secara bertahap bergeser dari awal hingga akhir data. Tujuan utamanya adalah mengubah data historis menjadi format *input-output* yang siap digunakan dalam proses prediksi. Bagian atas gambar menunjukkan bahwa setiap jendela *input* mencakup data selama 20 hari perdagangan berturut-turut. Jendela ini diwakili oleh balok berwarna abu-abu, yang berisi nilai harga penutupan atau informasi relevan lain dari periode tersebut. Setelah jendela pertama terbentuk, jendela kedua dibentuk dengan menggeser satu hari ke depan. Proses ini menghasilkan urutan tumpang tindih yang saling terhubung, menjaga kontinuitas informasi antarperiode.

Di sisi kanan setiap jendela *input*, terdapat komponen *output* yang ditandai sebagai "*The next day close price movement*." Bagian ini

menggambarkan nilai target yang ingin diprediksi, yakni perubahan harga penutupan pada hari berikutnya. Dengan demikian, setiap pasangan *input-output* memuat informasi tentang pola pergerakan harga selama 20 hari sebelumnya dan hasil yang diharapkan untuk hari ke-21. Susunan jendela yang bertingkat dalam gambar memperlihatkan bahwa teknik ini menghasilkan banyak pasangan data, mulai dari jendela pertama hingga jendela terakhir (N). Jendela terakhir berada mendekati ujung periode lima tahun perdagangan, tetap mempertahankan ukuran 20 hari data masukan dan satu hari keluaran. Model pembelajaran dapat menggunakan pasangan-pasangan ini untuk memahami pola pergerakan harga, tren jangka pendek, maupun fluktuasi harian.

Keunggulan dari teknik ini terletak pada kemampuannya mempertahankan keterkaitan temporal. Karena jendela-jendela data saling tumpang tindih, model yang memanfaatkan struktur ini memiliki peluang lebih besar menangkap pola berulang atau anomali yang muncul secara konsisten. Hal ini sangat penting untuk data saham seperti IHSG yang sering dipengaruhi oleh faktor eksternal dan internal secara dinamis. Selain itu, representasi visual dalam gambar membantu memahami bahwa *sliding window* tidak hanya sekadar memotong data menjadi segmen, tetapi juga menyusun kerangka logis untuk menghubungkan masa lalu dengan prediksi masa depan. Pemisahan yang rapi antara *input data* dan *output data* memudahkan proses validasi serta pengujian model. Teknik ini fleksibel untuk berbagai tujuan. Ukuran jendela 20 hari pada contoh ini dapat diubah sesuai strategi yang diinginkan. Misalnya, trader jangka pendek dapat menggunakan jendela yang lebih kecil, sedangkan analis jangka panjang dapat memperluasnya untuk menangkap tren lebih besar. Pada kasus IHSG, pemilihan panjang jendela biasanya

mempertimbangkan siklus perdagangan, volatilitas pasar, dan tujuan prediksi—apakah fokus pada pergerakan harian atau tren mingguan.

Penggunaan *sliding window* juga memungkinkan pembelajaran adaptif dari data baru. Setiap kali periode perdagangan bertambah, jendela terakhir dapat bergeser untuk mencakup data terbaru, sehingga model selalu terbaru. Hal ini menjaga relevansi prediksi, terutama di pasar yang pergerakannya cepat berubah. Melalui Gambar 28, terlihat jelas bahwa *sliding window* merupakan jembatan antara data historis dan proyeksi masa depan. Dengan memanfaatkan struktur ini, analisis pergerakan IHSG dapat dilakukan secara sistematis, memanfaatkan setiap potongan informasi tanpa kehilangan urutan waktu, dan menghasilkan basis data yang kuat untuk strategi prediksi maupun pengambilan keputusan.

Pengurangan redundansi evaluasi fitur

Dalam pengolahan data berskala besar dan beragam, kerap ditemukan fitur yang membawa informasi serupa atau bahkan identik. Redundansi semacam ini berpotensi mengurangi efektivitas model prediktif karena dapat menimbulkan kebingungan dalam menentukan variabel mana yang benar-benar memberikan kontribusi signifikan. Pemeriksaan hubungan antarfitur menjadi langkah penting agar setiap variabel yang dipertahankan benar-benar menyumbang informasi yang unik dan bermanfaat bagi model. Salah satu pendekatan yang umum digunakan adalah *correlation analysis*, yang menilai sejauh mana dua atau lebih variabel memiliki hubungan linear yang kuat. Apabila ditemukan koefisien korelasi yang melampaui ambang batas tertentu,

misalnya 0,8, maka besar kemungkinan kedua variabel tersebut mengandung informasi yang tumpang tindih. Dalam situasi seperti ini, penghapusan salah satu fitur atau penggabungannya menjadi fitur baru dapat mengurangi beban model dan mencegah terjadinya *multicollinearity*, yang berpotensi memengaruhi keandalan interpretasi parameter.

Dampak negatif redundansi terhadap model cukup signifikan. Penambahan dimensi tanpa informasi baru meningkatkan kompleksitas komputasi dan risiko *overfitting*. Model yang terlalu terpapar sinyal semu cenderung menurun kinerjanya ketika dihadapkan pada data baru. Lebih jauh lagi, kehadiran variabel yang sangat berkorelasi dapat mengaburkan hubungan nyata antara variabel input dan target prediksi, sehingga mengurangi stabilitas hasil.

Selain *correlation analysis*, visualisasi menggunakan *heat-map cluster* membantu memetakan kelompok variabel yang memiliki keterkaitan tinggi. Pemetaan ini memungkinkan identifikasi area yang memerlukan reduksi dengan cepat. Representasi visual yang efektif memudahkan pengambil keputusan dalam memahami hubungan yang kompleks melalui pola yang lebih sederhana.

Setelah hubungan antarfitur diidentifikasi, tahap berikutnya adalah melakukan reduksi. Salah satu teknik yang populer adalah *Principal Component Analysis (PCA)*, yang mengubah kumpulan fitur berkorelasi menjadi serangkaian komponen baru yang saling bebas (*uncorrelated*). Komponen-komponen ini diurutkan berdasarkan besarnya variasi yang dijelaskan, sehingga hanya beberapa komponen awal yang biasanya sudah cukup untuk merepresentasikan sebagian besar informasi dalam data asli. Keunggulan *PCA* terletak pada kemampuannya

mempertahankan struktur utama data sambil menghilangkan redundansi. Pada berbagai aplikasi seperti pengolahan citra medis atau pemetaan spektral dalam *hyperspectral imaging*, *PCA* tidak hanya mengurangi jumlah variabel yang diproses, tetapi juga menyaring *noise* yang dapat mengganggu proses pembelajaran model. Hal ini mempercepat proses komputasi dan meningkatkan kemudahan interpretasi hasil karena model hanya bekerja dengan komponen yang paling informatif.

Meski demikian, *PCA* bukanlah solusi yang selalu digunakan. Dalam situasi di mana interpretasi setiap variabel asli sangat penting, seperti pada pengambilan keputusan strategis, penghapusan langsung variabel yang berkorelasi tinggi bisa menjadi pilihan yang lebih tepat dibandingkan transformasi ke ruang komponen baru. Pertimbangan ini memastikan bahwa efisiensi model tidak mengorbankan kejelasan informasi. Strategi pengurangan redundansi yang efektif memerlukan keseimbangan antara mempertahankan informasi relevan dan memastikan efisiensi model. Menghapus fitur yang tidak memberi nilai tambah akan membantu model fokus pada pola yang berpengaruh nyata. Sebaliknya, mengabaikan langkah ini dapat menyebabkan model menangkap pola semu akibat duplikasi informasi.

Dalam praktik, pengurangan redundansi sering digabungkan dengan strategi *feature selection* lainnya. Setelah proses korelasi dan *PCA*, teknik seperti *Recursive Feature Elimination (RFE)* dapat digunakan untuk memvalidasi kembali fitur yang tersisa. Pendekatan berlapis ini memastikan bahwa fitur akhir tidak hanya bebas dari redundansi, tetapi juga berkontribusi pada peningkatan performa prediksi. Selain itu, teknik *regularization* seperti *Lasso regression* dapat secara otomatis menghapus fitur yang kurang relevan, termasuk yang redundan. *Lasso* menambahkan

penalti pada koefisien variabel sehingga variabel yang tidak penting diberi bobot nol. Kombinasi antara *regularization* dan evaluasi korelasi menghasilkan model yang lebih ramping tanpa mengorbankan akurasi.

Pengurangan redundansi juga memberikan manfaat terhadap interpretabilitas. Dengan jumlah fitur yang lebih sedikit dan berbeda satu sama lain, hasil model menjadi lebih mudah dijelaskan kepada pihak non-teknis. Transparansi ini sangat bernilai dalam pengambilan keputusan, terutama ketika hasil model digunakan untuk menentukan langkah strategis. Pemeriksaan hubungan antarfitur dan penghapusan informasi yang berulang adalah tahapan yang membawa dampak besar bagi kinerja model. Dengan memanfaatkan *correlation analysis*, visualisasi *heat-map*, *PCA*, dan *regularization*, model dapat dikembangkan menjadi lebih efisien, cepat, dan akurat, serta mampu memberikan prediksi yang andal dalam berbagai situasi.

Feature importance menggunakan feature weighting

Dalam pengembangan model prediktif, pemilihan fitur dengan pengaruh dominan menjadi fondasi untuk memastikan masukan model tepat sasaran. Pendekatan *feature weighting* berperan sebagai alat yang menyoroti variabel dengan kontribusi paling besar terhadap prediksi, sehingga memandu penyusunan masukan yang ringkas tanpa mengorbankan informasi esensial. Salah satu teknik yang umum digunakan adalah mengukur perubahan kinerja model akibat modifikasi nilai fitur. *Permutation importance* misalnya, dilakukan dengan menyusun ulang nilai fitur secara acak lalu mengamati dampaknya terhadap performa. Jika perubahan yang terjadi cukup signifikan, hal tersebut menunjukkan bahwa fitur tersebut memiliki peran besar. Keunggulan

teknik ini adalah sifatnya yang *model-agnostic*, sehingga dapat diterapkan pada berbagai jenis algoritma dengan hasil yang sederhana namun efektif.

Model berbasis pohon seperti *Random Forest* dan *Gradient Boosting* secara bawaan menghasilkan skor kepentingan fitur. *Random Forest* memanfaatkan ukuran seperti *Gini importance* atau *Mean Decrease in Impurity* (MDI) untuk menilai kontribusi suatu fitur dalam mengurangi ketidakteraturan data, sedangkan *Gradient Boosting* menilai *gain*, yaitu penurunan nilai *loss* yang terjadi akibat pemisahan pada simpul tertentu. Pendekatan lain yang semakin populer adalah *SHAP values*, yang menggunakan teori permainan untuk membagi kontribusi setiap fitur secara adil dengan mempertimbangkan semua urutan kemungkinan kemunculannya, memberikan gambaran yang lebih transparan dibandingkan penilaian bawaan model. Algoritma berbasis pohon memang populer karena hasilnya ringkas dan mudah diinterpretasikan, namun ketika dibutuhkan interpretasi yang lebih adil, terutama jika terdapat korelasi tinggi antarfitur, teknik seperti *permutation importance* atau *SHAP values* sering menjadi pilihan yang lebih tepat karena mampu mengakomodasi kompleksitas hubungan antarvariabel. Alternatif lain adalah *ReliefF*, yang menilai bobot berdasarkan perbedaan nilai fitur antar-*instance* serupa maupun berbeda kelas.

Meskipun tidak dirancang untuk menghapus redundansi, algoritma ini peka terhadap interaksi antarfitur dan tahan terhadap *noise*. Pemahaman yang jelas mengenai fitur yang paling berpengaruh membuka peluang untuk menyederhanakan model tanpa mengorbankan akurasi. Fitur dengan skor rendah dapat dihapus atau digabung untuk

mengurangi dimensi, meningkatkan efisiensi, dan mempermudah interpretasi. Fitur penting juga dapat menjadi dasar penciptaan fitur turunan, baik melalui transformasi maupun kombinasi, guna memperkaya representasi data. Beberapa pendekatan lanjutan memanfaatkan *toolbox* seperti EFI yang menggabungkan bobot dari berbagai model melalui teknik agregasi, seperti rata-rata atau logika *fuzzy*, sehingga menghasilkan bobot yang lebih stabil dan adaptif terhadap variasi data. Memulai pengembangan dengan fokus pada fitur berkontribusi tinggi membantu memperjelas arah pemodelan.

Reduksi dimensi melalui pembobotan mendorong efisiensi dan kestabilan proses pelatihan. Penerapan teknik yang transparan seperti *permutation importance* dan *SHAP values* meningkatkan kepercayaan terhadap hasil model, sedangkan strategi agregatif seperti EFI memastikan bobot yang dihasilkan tetap relevan di berbagai skenario, menjadikan fokus pada fitur penting tidak hanya sebagai cara meningkatkan kinerja prediksi, tetapi juga sebagai sarana memperdalam pemahaman terhadap karakteristik data dan penggunaannya di dunia nyata.

Bab 8. Pelatihan Model CNN-BiGRU-Attention

Transformasi data mentah menjadi format sequence

Transformasi data mentah menjadi *format sequence* merupakan tahap penting dalam pelatihan model *CNN-BiGRU-Attention*. Langkah ini memastikan data memiliki struktur yang sesuai dengan kebutuhan arsitektur, khususnya untuk menangani *time series* multivariat di bidang keuangan. Pada tahap ini, data diatur dalam jendela waktu tetap (*fixed time window*) dengan mempertahankan urutan kronologis serta keselarasan antar kanal, sehingga informasi temporal dan hubungan antar variabel tetap terjaga. Konversi data mentah menjadi *sequence* umumnya dilakukan dengan teknik *sliding window* atau *fixed window segmentation*. Proses ini memotong data menjadi bagian-bagian dengan panjang tertentu, sehingga setiap bagian menjadi satu urutan masukan bagi model. Pendekatan ini diperlukan karena arsitektur seperti *BiGRU* dan *Attention* membutuhkan masukan berbentuk urutan untuk mempelajari pola temporal secara efektif.

Salah satu tantangan besar dalam membentuk *sequence* multivariat adalah menjaga sinkronisasi antar kanal. Data keuangan sering berasal dari berbagai indikator dengan frekuensi pencatatan yang berbeda-beda. Tanpa sinkronisasi, hubungan waktu antar variabel dapat terganggu dan makna korelasi menjadi berkurang. Untuk mengatasi hal ini, proses prapengolahan meliputi interpolasi, normalisasi, dan penyelarasan *timestamp* agar semua kanal memiliki titik waktu yang konsisten.

Selain sinkronisasi, masalah lain yang sering muncul adalah *missing values* akibat jeda pencatatan atau gangguan sistem. Penanganannya dapat dilakukan dengan imputasi berbasis rata-rata, median, atau pendekatan prediktif. Pemilihan teknik imputasi perlu mempertimbangkan pengaruhnya terhadap pola temporal agar tidak memunculkan bias.

Panjang *sequence* (*sequence length*) juga memengaruhi kinerja model. Urutan yang terlalu pendek berpotensi kehilangan informasi jangka panjang, sedangkan urutan yang terlalu panjang dapat meningkatkan beban komputasi dan risiko *overfitting*. Ada keseimbangan yang perlu dicapai antara kelengkapan informasi temporal dan efisiensi pemrosesan. Pada *CNN-BiGRU-Attention*, panjang *sequence* yang tepat biasanya diperoleh melalui pengujian untuk mendapatkan hasil yang seimbang antara akurasi dan waktu pelatihan. Tahap awal *CNN* digunakan untuk mengekstraksi ciri-ciri lokal dari *sequence*, khususnya pola jangka pendek yang sering berulang. Hasil ekstraksi ini kemudian diproses oleh *BiGRU* untuk menangkap keterkaitan temporal jangka panjang dari dua arah, maju dan mundur. Setelah itu, mekanisme *Attention* memberikan bobot lebih pada bagian *sequence* yang paling relevan dengan keluaran yang diharapkan. Semua ini hanya dapat berjalan optimal jika proses konversi data mentah ke bentuk *sequence* dilakukan dengan cermat.

Dalam pelaksanaan, pemilihan ukuran jendela waktu dan langkah pergeseran (*stride*) pada *sliding window* memengaruhi jumlah serta variasi *sequence* yang dihasilkan. Langkah kecil akan menghasilkan lebih banyak urutan yang saling tumpang tindih (*overlapping*), sehingga variasi data bertambah, namun juga meningkatkan redundansi. Sebaliknya,

langkah yang besar mengurangi redundansi, tetapi berisiko kehilangan pola transisi penting. Proses ini memerlukan keseimbangan antara ketelitian teknis dan efisiensi pengolahan. Menjaga integritas urutan dan keselarasan kanal menjadi kunci agar hubungan temporal dan keterkaitan variabel dapat ditangkap dengan baik. Dengan pengaturan yang tepat, *CNN-BiGRU-Attention* dapat menghasilkan prediksi yang lebih akurat dan andal untuk data keuangan multivariat.

Ekstraksi pola lokal dengan CNN

Lapisan *convolution* pada arsitektur *Convolutional Neural Network* dirancang untuk mengenali pola-pola lokal dalam deret waktu, misalnya perubahan harga saham yang berlangsung dalam jangka sangat singkat. Proses ini dilakukan dengan menggeser *kernel* atau *filter* secara berulang di sepanjang data masukan untuk membentuk representasi fitur yang merekam keterkaitan lokal. Dengan cara ini, fokus pemodelan terarah pada bagian-bagian penting tanpa mengabaikan detail yang mempengaruhi keakuratan hasil. Tahap *pooling* yang biasanya mengikuti proses konvolusi berfungsi menyaring informasi inti dan mengurangi beban komputasi. Sebagai contoh, *max pooling* akan memilih nilai tertinggi dari tiap wilayah fitur, mempertahankan sinyal terkuat sekaligus mengurangi risiko model menjadi terlalu menyesuaikan pada data pelatihan. Hasilnya, pemrosesan menjadi lebih efisien dan mampu digunakan pada data yang belum pernah diproses sebelumnya.

Pemilihan ukuran *kernel* yang sesuai menjadi faktor utama dalam keberhasilan deteksi pola. *Kernel* yang terlalu kecil dapat melewatkan jangkauan temporal yang penting, sedangkan yang terlalu besar

berpotensi mengaburkan rincian. Rentang tiga hingga lima titik waktu kerap menjadi pilihan seimbang, dan penyesuaian adaptif terhadap ukuran *kernel* menurut karakteristik data dapat memberikan hasil yang lebih optimal.

Keunggulan lain dari CNN adalah kemampuannya memproses masukan multi-kanal, di mana setiap kanal merepresentasikan variabel berbeda seperti harga pembukaan, harga penutupan, volume perdagangan, atau indikator teknikal. Pemrosesan secara bersamaan ini memungkinkan pengungkapan keterkaitan antarvariabel yang lebih kaya, yang selanjutnya diteruskan ke lapisan BiGRU untuk pemodelan keterhubungan temporal. Kemampuan CNN untuk mendeteksi pola lokal secara efektif telah banyak diaplikasikan di sektor keuangan. Penggabungan dengan model sekuensial menghasilkan prediksi yang lebih tepat dibandingkan pendekatan tradisional, sementara visualisasi *filter* dan fitur yang dihasilkan memberi gambaran jelas tentang pola yang dianggap penting oleh sistem. Dengan demikian, tahap ekstraksi pola lokal melalui CNN menjadi fondasi yang membentuk alur kerja dalam model hibrid CNN-BiGRU-Attention, di mana lapisan konvolusi berfungsi sebagai penyaring awal dan *pooling* memastikan hanya informasi paling bernilai yang dilanjutkan ke proses berikutnya.

Tabel 13. Kombinasi Kernel, Stride, Pooling dan Dampaknya

Kernel (Conv)	Stride (Conv)	Pooling	Dampak Umum pada Model & Data Saham
3×3	1	Max Pooling 2×2 (stride 2)	Menangkap detail lokal halus → representasi fitur yang lebih kaya; pooling membantu reduce dimensi dan mitigasi noise.

5×5	1	Max Pooling 2×2 (stride 2)	Lapisan reaksi receptif luas, cocok untuk capture pola jangka menengah (tren pasar). Namun, parameter lebih banyak → risiko overfitting.
3×3	2	Tidak ada pooling / strided conv (stride 2)	Pengurangan dimensi secara langsung, lebih efisien, tapi bisa melewatkan detail penting; cocok bila data memiliki keterbatasan waktu atau kebutuhan pemrosesan cepat.
7×7	2 atau 1	Average Pooling 2×2	Kernel besar memodelkan konteks luas, namun pooling rata-rata menghaluskan fitur—kurang ideal untuk data dengan volatilitas tinggi seperti harga saham harian atau intraday.
1×1 (pointwise)	1	Global Average Pooling	Mengompresi informasi per channel, cocok untuk tahap akhir klasifikasi atau regresi (misalnya prediksi harga saham). Biasanya digunakan setelah beberapa lapisan konvolusi untuk merangkum fitur.

Tabel 13 di atas merangkum kombinasi umum antara ukuran kernel pada lapisan konvolusi, nilai stride, serta jenis pooling yang sering digunakan dalam arsitektur *Convolutional Neural Network* (CNN), dan bagaimana masing-masing konfigurasi tersebut berdampak pada kinerja model ketika diterapkan pada data saham. Meskipun CNN sering dikaitkan dengan pengolahan citra, prinsip yang sama dapat diterapkan pada data deret waktu, termasuk data harga dan volume saham, dengan mengubah cara kita memandang “ruang” menjadi dimensi waktu dan fitur.

1. Kernel 3×3, Stride 1, Max Pooling 2×2

Konfigurasi kernel 3×3 dengan stride 1 merupakan salah satu pilihan paling populer dalam arsitektur CNN modern seperti VGGNet. Ukuran kernel ini relatif kecil namun cukup efektif dalam menangkap pola detail, baik pada citra maupun deret waktu. Ketika diterapkan pada data saham, kernel 3×3 dengan stride 1 dapat memetakan perubahan harga kecil yang terjadi antar waktu, misalnya fluktuasi intraday yang penting untuk strategi perdagangan jangka pendek. Penggunaan Max Pooling 2×2 dengan stride 2 setelahnya berfungsi untuk mengurangi dimensi fitur sekaligus menjaga informasi paling dominan dalam setiap area kecil. Pada data saham, ini berarti model akan fokus pada pergerakan harga signifikan dan mengabaikan sebagian noise atau pergerakan kecil yang mungkin tidak relevan dengan strategi prediksi. Efek pengurangan dimensi ini juga mengurangi beban komputasi dan membantu mencegah *overfitting*.

2. Kernel 5×5 , Stride 1, Max Pooling 2×2

Kernel 5×5 memiliki jangkauan pengamatan (receptive field) lebih luas dibanding 3×3 . Hal ini memungkinkan model untuk menangkap pola jangka menengah, misalnya tren yang berlangsung selama beberapa hari atau minggu. Dalam konteks data saham, pola seperti ini bisa mencerminkan pergerakan akibat sentimen pasar atau berita ekonomi. Namun, penggunaan kernel yang lebih besar juga berarti jumlah parameter bertambah. Pada dataset saham dengan jumlah data yang terbatas atau periode waktu yang tidak terlalu panjang, hal ini dapat memicu risiko *overfitting*. Oleh karena itu, meskipun konfigurasi ini sangat bermanfaat untuk mendeteksi tren jangka menengah, penggunaannya perlu diimbangi dengan teknik regulasi seperti *dropout*, *early stopping*, atau penambahan data. Max Pooling 2×2 dalam kombinasi ini berperan

sama seperti sebelumnya—menyaring informasi penting dan mengurangi dimensi. Namun, karena kernel awalnya sudah menangkap area yang lebih luas, pooling ini dapat menghasilkan representasi fitur yang cenderung lebih “abstrak” dibandingkan kombinasi 3×3 .

3. Kernel 3×3 , Stride 2, Tanpa Pooling (Strided Convolution)

Alih-alih menggunakan pooling, kita dapat mengatur stride pada konvolusi menjadi 2, sehingga pengurangan dimensi dilakukan langsung pada proses konvolusi. Pendekatan ini dikenal sebagai *strided convolution* dan sering digunakan pada arsitektur yang ingin meminimalkan jumlah lapisan atau mempercepat proses inferensi. Dalam konteks data saham, metode ini bermanfaat jika kita perlu membuat prediksi secara real-time atau hampir real-time, di mana kecepatan komputasi menjadi prioritas. Kelemahannya, pendekatan ini bisa kehilangan detail penting yang mungkin hanya terlihat pada resolusi yang lebih tinggi, seperti sinyal kecil sebelum pembalikan harga. Oleh karena itu, *strided convolution* cocok untuk aplikasi dengan batasan waktu ketat atau perangkat keras terbatas, tetapi mungkin kurang tepat jika kita ingin memaksimalkan akurasi jangka panjang.

4. Kernel 7×7 , Stride 2 atau 1, Average Pooling 2×2

Kernel berukuran 7×7 tergolong besar dan dapat memodelkan konteks yang sangat luas. Pada citra, kernel ini bisa melihat area yang besar sekaligus; pada data saham, ini berarti mengamati periode waktu yang lebih panjang dalam satu langkah. Strategi ini dapat berguna untuk mendeteksi pola musiman atau tren makro yang tidak terlihat dalam jendela waktu sempit. Namun, penggunaan *Average Pooling* berbeda dari Max Pooling. Average Pooling mengambil rata-rata dari nilai-nilai dalam area tertentu, sehingga menghasilkan fitur yang lebih halus. Meskipun ini

dapat membantu mengurangi noise, pada data saham yang volatil—terutama data intraday—pendekatan ini dapat menghapus sinyal penting yang justru ada pada puncak atau lembah pergerakan harga. Akibatnya, Average Pooling lebih cocok untuk data yang relatif stabil atau untuk tahap akhir pemrosesan, ketika kita ingin mendapatkan gambaran besar tanpa terlalu memperhatikan detail.

5. Kernel 1×1 (Pointwise), Stride 1, Global Average Pooling

Kernel 1×1 sering digunakan untuk mengubah dimensi kedalaman (jumlah channel) tanpa mengubah dimensi spasial atau temporal. Pada data saham, ini berarti kita dapat menggabungkan atau mengubah representasi fitur yang telah dihasilkan oleh lapisan sebelumnya, misalnya menggabungkan informasi harga, volume, volatilitas, dan indikator teknis ke dalam bentuk yang lebih ringkas. Global Average Pooling (GAP) digunakan pada tahap akhir untuk merangkum seluruh informasi dalam satu nilai rata-rata per channel. Keunggulan GAP adalah menghilangkan kebutuhan akan lapisan *fully connected* besar, sehingga mengurangi jumlah parameter dan risiko *overfitting*. Dalam kasus prediksi harga saham, GAP membantu menghasilkan output akhir (misalnya harga prediksi atau probabilitas arah pergerakan) dengan cara yang lebih efisien dan terfokus.

Hubungan Konfigurasi dengan Kinerja Model Saham

Pemilihan kombinasi kernel, stride, dan pooling bukanlah keputusan yang dapat diambil secara acak. Setiap kombinasi memiliki trade-off antara resolusi fitur, kecepatan komputasi, dan risiko kehilangan informasi penting. Dalam data saham, di mana sinyal bisa sangat tipis dan sering kali terkubur dalam noise, pemilihan ini menjadi semakin krusial.

- a) **Kernel kecil (3×3)** efektif untuk menangkap detail jangka pendek, cocok untuk strategi *scalping* atau *day trading*.
- b) **Kernel besar (5×5 atau 7×7)** lebih cocok untuk tren jangka menengah hingga panjang, misalnya *swing trading* atau analisis makro.
- c) **Stride besar** dan **tanpa pooling** dapat mempercepat proses, tetapi harus digunakan dengan hati-hati agar tidak kehilangan sinyal penting.
- d) **Max Pooling** mempertahankan fitur dominan, cocok untuk data volatil.
- e) **Average Pooling** menghaluskan data, cocok untuk tren stabil.
- f) **Global Average Pooling** sangat efisien untuk tahap akhir prediksi dan membantu menghindari model yang terlalu kompleks.

Pertimbangan Implementasi pada Data Saham

a) **Jenis Data**

Apakah data yang digunakan intraday, harian, atau mingguan akan mempengaruhi pemilihan kernel. Data intraday cenderung membutuhkan kernel kecil dan stride rendah untuk menangkap fluktuasi cepat, sedangkan data mingguan dapat menggunakan kernel besar untuk pola jangka panjang.

b) **Kapasitas Model dan Dataset**

Dataset besar memungkinkan penggunaan kernel besar tanpa terlalu khawatir *overfitting*, sedangkan dataset kecil lebih aman dengan kernel kecil.

c) **Keterbatasan Komputasi**

Model real-time untuk *algorithmic trading* mungkin harus mengorbankan detail demi kecepatan.

d) **Tujuan Prediksi**

Prediksi arah pergerakan harga jangka pendek berbeda kebutuhannya dengan estimasi harga akhir bulan.

Tabel 13 menyajikan panduan awal yang dapat digunakan untuk menyesuaikan arsitektur CNN pada data saham. Meskipun berasal dari dunia visi komputer, prinsip kombinasi kernel, stride, dan pooling tetap relevan dalam domain keuangan, asalkan kita mampu memetakan ulang dimensi spasial menjadi dimensi temporal dan fitur. Pemilihan konfigurasi yang tepat memerlukan pertimbangan mendalam terhadap karakteristik data, tujuan model, serta batasan komputasi. Eksperimen terarah dengan kombinasi ini dapat membantu menemukan titik optimal antara akurasi, efisiensi, dan kemampuan generalisasi model.

Temporal dengan BiGRU

Unit dua arah (*bidirectional unit*) pada arsitektur *BiGRU* memanfaatkan informasi dari dua arah waktu: maju (*forward*) dan mundur (*backward*). Pendekatan ini membuat model mampu memahami hubungan temporal yang lebih luas dibandingkan dengan pemrosesan satu arah. Dalam pengolahan deret waktu harga saham, kemampuan membaca informasi sebelum dan sesudah suatu titik waktu menjadi landasan untuk menangkap pengaruh tren jangka pendek maupun panjang. Pemrosesan dari dua arah ini menjadikan *BiGRU* lebih peka terhadap perubahan tempo harga dan berpotensi meningkatkan ketepatan hasil prediksi.

BiGRU memanfaatkan dua lapisan *GRU* yang bekerja secara paralel namun berlawanan arah. Lapisan maju memproses data dari awal ke

akhir, sedangkan lapisan mundur berjalan dari akhir ke awal. Masing-masing lapisan dilengkapi mekanisme *update gate* dan *reset gate* yang mengatur informasi yang dipertahankan atau diabaikan. Penyatuan hasil dari kedua jalur ini membuat model mampu mengenali pola jangka pendek dan panjang dalam satu representasi. Kemampuan ini sangat berguna ketika data memiliki perubahan mendadak maupun pola berulang yang hanya terlihat bila seluruh rentang waktu diperhitungkan.

Kinerja *BiGRU* dapat ditingkatkan melalui pengaturan *learning rate* yang disesuaikan secara bertahap agar proses pembelajaran lebih stabil, penggunaan *dropout* dan *recurrent dropout* untuk mengurangi risiko *overfitting*, serta penerapan *layer normalization* guna menjaga kestabilan aktivasi antar langkah waktu. Langkah tambahan seperti *gradient clipping* mencegah masalah *exploding gradients*, sedangkan integrasi *attention mechanism* membantu model memusatkan perhatian pada titik-titik waktu yang paling relevan. Pelatihan menggunakan *mini-batch* dengan ukuran yang tepat juga dapat meningkatkan efisiensi sekaligus menjaga kualitas keluaran.

Pemrosesan dua arah memang menambah beban komputasi, namun bukan berarti memperlambat secara keseluruhan. Walau setiap *epoch* memerlukan waktu lebih panjang karena dua kali lintasan data, jumlah *epoch* yang dibutuhkan untuk mencapai performa optimal sering kali lebih sedikit. Hal ini terjadi karena pembaruan bobot didukung informasi yang lebih lengkap di setiap langkah. Penentuan ukuran unit tersembunyi (*hidden size*) yang proporsional dapat menyeimbangkan kapasitas model dan waktu yang diperlukan, sebagaimana tergambar pada tabel yang membandingkan variasi ukuran unit dan dampaknya terhadap durasi pelatihan dan tingkat ketepatan.

Integrasi hybrid architectures sebelum attention

Integrasi *hybrid architectures* yang memadukan *Convolutional Neural Network (CNN)* dengan *Bidirectional Gated Recurrent Unit (BiGRU)* sebelum penerapan *attention mechanism* membentuk landasan yang solid untuk pemrosesan data berurutan, termasuk pada pengolahan data harga saham *Indeks Harga Saham Gabungan (IHSG)*. *CNN* berfungsi mengekstraksi ciri-ciri lokal dari data mentah, seperti pola pergerakan harga harian atau intraday, sementara *BiGRU* menguraikan keterhubungan temporal dua arah yang mencerminkan tren dan volatilitas pasar. Penerapan *attention* setelah kedua elemen ini bertujuan menyaring hasil representasi agar perhatian terpusat pada bagian paling bermakna dalam rangkaian data harga, misalnya titik-titik yang menunjukkan sinyal perubahan tren. Dengan demikian, *attention mechanism* menjadi jembatan antara pemrosesan fitur dan tahap akhir prediksi, memastikan fokus tetap pada informasi pasar yang paling relevan. Penempatan *attention* dalam struktur hibrida dilakukan ketika representasi fitur telah mencakup dimensi spasial dan temporal. *CNN* menghasilkan peta fitur yang merekam pola lokal, kemudian *BiGRU* memproses peta tersebut untuk membangun gambaran yang mempertimbangkan urutan waktu dari dua arah. *Attention* diaktifkan setelah tahap ini untuk menilai keseluruhan hasil dan memberikan bobot lebih pada segmen yang memberi kontribusi besar pada keluaran akhir, seperti pergerakan signifikan pada IHSG akibat berita ekonomi atau kebijakan moneter. Pendekatan ini membantu model mengabaikan

informasi yang kurang penting dan memusatkan sumber daya pada pola yang paling berpengaruh terhadap prediksi pergerakan indeks.

Penerapan *attention* sebelum lapisan keluaran memberikan manfaat nyata. Selain meningkatkan keterjelasan hasil dengan menunjukkan bagian data yang menjadi fokus, penempatan ini juga dapat meningkatkan ketepatan dengan mengurangi gangguan dari ciri yang tidak relevan. Mekanisme ini membantu penyesuaian pada variasi panjang masukan, karena *attention* mampu secara dinamis mengatur fokus tanpa terikat ukuran data, baik untuk periode harian maupun mingguan IHSG. Interaksi antara *attention* dan keluaran rekuren menghasilkan hubungan yang saling menguatkan. Keluaran *BiGRU* memuat representasi dari dua arah waktu, memberi pandangan utuh terhadap rangkaian data. *Attention mechanism* kemudian mengevaluasi setiap langkah keluaran ini, mengidentifikasi bagian yang memiliki nilai prediktif tinggi, seperti titik balik harga IHSG yang muncul sebelum perubahan tren besar. Proses ini tidak hanya memilih satu titik waktu, tetapi juga menggabungkan informasi dari beberapa titik relevan. Hasilnya adalah representasi akhir yang padat informasi dan kaya muatan, siap digunakan pada tahap keluaran.

Penempatan *attention* setelah integrasi *CNN* dan *BiGRU* juga efektif mengatasi permasalahan *long-term dependencies*. Pada kasus di mana informasi penting berada jauh di awal atau akhir rangkaian, *BiGRU* mungkin mengalami pelemahan sinyal meskipun bersifat dua arah. *Attention* mengurangi pengaruh tersebut dengan memberi bobot langsung pada bagian yang relevan tanpa harus mengandalkan propagasi penuh di sepanjang urutan. Pendekatan ini telah terbukti memberi hasil yang kompetitif, khususnya dalam memodelkan pola fluktuasi IHSG yang

dipengaruhi faktor internal dan eksternal pasar. Dengan mempertimbangkan manfaat dan interaksi tersebut, penerapan *attention* dalam struktur hibrida bukan sekadar tambahan, melainkan unsur penting dalam strategi pemrosesan yang menyelaraskan representasi fitur lokal dan temporal. Penempatan yang tepat memungkinkan pemanfaatan kekuatan masing-masing komponen untuk menghasilkan keluaran prediksi IHSG yang lebih tepat dan mudah dipahami.

Pengaturan parameter dan teknik overfitting

Pengaturan parameter dan penerapan teknik pencegahan *overfitting* merupakan bagian penting dalam menjaga ketahanan model *CNN-BiGRU-Attention*, terutama saat diaplikasikan untuk memprediksi pergerakan harga saham *Indeks Harga Saham Gabungan (IHSG)*. Pendekatan seperti regularisasi, penghentian dini, dan penyesuaian laju belajar (*learning rate*) yang dirancang secara tepat membantu mencegah model terpaku pada pola kebetulan yang hanya terdapat pada data latih, sehingga kemampuan prediksi tetap terjaga ketika menghadapi data baru. Berbagai teknik regularisasi dapat digunakan, seperti *dropout*, *weight decay*, dan normalisasi. *Dropout* dilakukan dengan menonaktifkan sebagian neuron secara acak pada setiap iterasi pelatihan, mendorong jaringan untuk membentuk representasi yang lebih tangguh dan tidak bergantung pada jalur tertentu. Dalam pemodelan IHSG, *dropout* membantu menjaga konsistensi prediksi meskipun terjadi anomali harga akibat sentimen pasar yang bersifat sementara. *Weight decay* menambahkan penalti pada bobot yang terlalu besar untuk mengurangi kompleksitas berlebihan, sehingga model tidak terjebak pada noise.

Normalisasi seperti *batch normalization* atau *layer normalization* menjaga kestabilan distribusi aktivasi, yang pada akhirnya mempercepat proses konvergensi. Penghentian dini (*early stopping*) menjadi strategi efektif untuk meningkatkan kemampuan generalisasi. Prinsip ini menghentikan pelatihan ketika kinerja pada data validasi mulai menurun, walaupun performa pada data latih masih meningkat. Dalam penerapan pada IHSG, strategi ini mencegah model membaca pola acak yang hanya relevan pada periode historis tertentu. Dengan pemantauan metrik validasi seperti *mean squared error* atau *mean absolute percentage error*, pelatihan dapat dihentikan tepat waktu sebelum akurasi menurun.

Penyesuaian laju belajar (*learning rate scheduling*) berperan penting dalam kestabilan proses. Laju belajar yang terlalu besar dapat menimbulkan osilasi dan kegagalan mencapai konvergensi, sedangkan laju belajar yang terlalu kecil dapat memperlambat pelatihan dan menyebabkan terjebak pada solusi yang kurang optimal. Strategi seperti *learning rate decay*, *cosine annealing*, atau *adaptive learning rates* memungkinkan pengaturan dinamis sepanjang proses pelatihan. Dalam memprediksi IHSG yang memiliki volatilitas tinggi, pengaturan ini membantu model beradaptasi terhadap perubahan tren pasar secara cepat namun tetap stabil.

Pemilihan *hyperparameters* yang tepat juga sangat memengaruhi performa. Jumlah unit pada *BiGRU*, ukuran kernel pada *CNN*, panjang jendela waktu input, dan ukuran *batch* adalah di antara parameter kunci yang perlu disesuaikan dengan cermat. Sebagai contoh, jendela waktu yang terlalu pendek dapat mengabaikan tren jangka panjang IHSG, sementara jendela yang terlalu panjang berpotensi membawa noise dari

periode yang tidak relevan. Ukuran *batch* yang seimbang membantu menjaga stabilitas gradien sekaligus mempertahankan efisiensi pelatihan.

Gabungan strategi tersebut menghasilkan model *CNN-BiGRU-Attention* yang mampu menangkap pola signifikan pada IHSG tanpa terjebak pada fluktuasi acak. Regularisasi mengurangi ketergantungan berlebihan pada fitur tertentu, penghentian dini memastikan pembelajaran tidak melampaui batas yang menguntungkan, dan penyesuaian laju belajar membantu model mencapai titik konvergensi optimal. Penyetelan *hyperparameters* memberikan kendali tambahan, memastikan model tetap efisien dan adaptif dalam menghadapi dinamika pasar. Dengan pengaturan parameter yang tepat serta teknik pencegahan *overfitting* yang konsisten, model memiliki potensi memberikan prediksi IHSG yang lebih dapat diandalkan, mendukung pengambil keputusan di pasar modal dalam merumuskan langkah investasi yang tepat.

Bab 9. Evaluasi Kinerja dan Interpretasi Hasil

Pemilihan metrik pengukuran ketepatan prediksi

Pemilihan metrik pengukuran ketepatan prediksi menjadi komponen penting untuk memahami seberapa baik model memetakan pergerakan harga *Indeks Harga Saham Gabungan (IHSG)*. Metrik kesalahan dan indikator arah tren saling melengkapi, memberikan gambaran yang lebih menyeluruh mengenai kualitas hasil. Setiap metrik memiliki karakteristik dan manfaat berbeda, yang dapat disesuaikan dengan tujuan pengguna seperti investor, analis pasar, atau sistem pengambilan keputusan otomatis. Dua metrik utama yang sering digunakan dalam regresi harga saham adalah *Root Mean Squared Error (RMSE)* dan *Mean Absolute Error (MAE)*. *RMSE* menitikberatkan pada kesalahan besar karena perhitungan berbasis kuadrat selisih, sehingga sensitif terhadap lonjakan harga yang ekstrem. Sebaliknya, *MAE* menilai kesalahan secara proporsional dan linier, sehingga lebih toleran terhadap fluktuasi tajam. Dalam memprediksi IHSG yang kerap mengalami volatilitas akibat dinamika pasar, *RMSE* dapat menjadi peringatan adanya kesalahan signifikan, sementara *MAE* memberikan gambaran konsistensi prediksi secara umum.

Perbedaan karakter antara *RMSE* dan *MAE* menjadi relevan ketika nilai *RMSE* jauh melebihi *MAE*. Situasi ini menunjukkan bahwa walaupun rata-rata prediksi cukup dekat dengan nilai aktual, terdapat beberapa titik prediksi yang melenceng jauh. Dalam pasar IHSG, kondisi tersebut bisa disebabkan oleh reaksi harga terhadap berita ekonomi, kebijakan

pemerintah, atau sentimen global yang mendadak. Metrik lain seperti *Mean Absolute Percentage Error (MAPE)* dan versi berbobotnya (*wMAPE*) memberikan perspektif kesalahan relatif dalam bentuk persentase, membuat interpretasi lebih intuitif bagi pengguna. Misalnya, informasi bahwa prediksi memiliki deviasi rata-rata sepuluh persen dari harga aktual dapat membantu investor memahami seberapa besar margin kesalahan yang mungkin terjadi. Namun, *MAPE* dapat menghasilkan nilai ekstrem jika harga aktual mendekati nol, sehingga pada kondisi tertentu *wMAPE* lebih disarankan.

Selain ukuran kesalahan numerik, arah pergerakan harga juga sangat penting. *Mean Directional Accuracy (MDA)* mengukur persentase kesesuaian prediksi arah (naik atau turun) dengan realisasi sebenarnya, tanpa memperhitungkan besarnya perubahan. Bagi pelaku pasar yang fokus pada strategi jual-beli jangka pendek, *MDA* menjadi metrik yang memberikan nilai tambah karena memfokuskan evaluasi pada keakuratan arah pergerakan IHSG. Ada pula *Mean Absolute Scaled Error (MASE)* yang bermanfaat untuk membandingkan performa model pada berbagai set data dengan skala berbeda. Sifatnya yang independen terhadap skala membuat *MASE* berguna untuk mengukur kinerja prediksi IHSG pada berbagai periode, baik harian maupun mingguan, tanpa bias akibat perbedaan besaran harga.

Pemilihan metrik yang tepat bergantung pada tujuan evaluasi. Jika prioritas utama adalah menghindari kesalahan besar, maka *RMSE* dapat menjadi fokus. Jika kestabilan prediksi yang diinginkan, *MAE* lebih sesuai. Sementara itu, *MDA* lebih tepat bagi pihak yang mengutamakan keakuratan arah, dan *MASE* cocok digunakan ketika diperlukan perbandingan lintas periode atau lintas instrumen. Untuk evaluasi yang

komprehensif terhadap prediksi IHSG, penggunaan kombinasi metrik sering kali memberikan hasil terbaik. Misalnya, *MAE* dapat digunakan untuk mengukur rata-rata kesalahan, *RMSE* untuk mendeteksi kesalahan ekstrem, dan *MDA* untuk menilai konsistensi arah prediksi. Pendekatan ini memastikan bahwa penilaian hasil prediksi tidak hanya terfokus pada akurasi numerik, tetapi juga pada aspek yang relevan bagi pengambilan keputusan di pasar modal.

Pemanfaatan Korelasi untuk menilai tren

Pemahaman terhadap tingkat keterhubungan antara prediksi model dan tren sebenarnya memberikan gambaran yang lebih dalam mengenai kualitas hasil. Korelasi yang tinggi menunjukkan bahwa arah tren prediksi sejalan dengan pergerakan nyata pada harga *Indeks Harga Saham Gabungan (IHSG)*. Kondisi ini menandakan bahwa model tidak hanya menghasilkan angka perkiraan, tetapi juga mampu mengikuti pola dinamis pasar yang menjadi acuan bagi pengambilan keputusan. Ketika korelasi berada pada tingkat tinggi, model memperlihatkan konsistensi dalam menangkap naik-turunnya indeks, sehingga meningkatkan keyakinan pengguna yang mengandalkan arah pergerakan pasar. Korelasi positif yang mendekati nilai maksimum menunjukkan sensitivitas model terhadap isyarat teknikal dan fundamental yang memengaruhi harga. Hal ini menjadi pertanda bahwa prediksi yang dihasilkan memiliki kedekatan yang erat dengan kenyataan pasar.

Apabila nilai korelasi rendah, hal ini menjadi sinyal bahwa model belum optimal dalam menangkap pola yang berlangsung. Ada kemungkinan prediksi terlalu terfokus pada fluktuasi jangka pendek atau

noise, sehingga gagal merekam momentum yang menentukan arah IHSG. Situasi ini membuka peluang untuk melakukan peninjauan ulang pada desain arsitektur, pengaturan jendela waktu masukan, atau strategi pelatihan agar model lebih mampu merepresentasikan arah pergerakan yang sebenarnya.

Penggunaan korelasi dalam deret waktu dapat memperluas pemahaman melebihi sekadar keterkaitan sesaat. Penerapan *cross-correlation* dengan berbagai *lag* mampu mengidentifikasi pergeseran waktu antara sinyal prediksi dan pergerakan pasar aktual. Apabila prediksi bergerak lebih dahulu dibandingkan IHSG, model dapat dianggap memberikan isyarat awal atau *early signal* yang berguna. Sebaliknya, jika prediksi tertinggal, diperlukan penyesuaian agar respons model lebih cepat terhadap dinamika pasar. Harga *IHSG* dipengaruhi oleh berbagai faktor, mulai dari indikator ekonomi domestik, sentimen global, hingga kebijakan yang dikeluarkan pemerintah. Korelasi yang tinggi antara prediksi dan data aktual menunjukkan kemampuan model dalam memadukan faktor-faktor tersebut menjadi keluaran yang relevan. Prediksi yang dapat merefleksikan tren kenaikan maupun penurunan dengan tepat menandakan bahwa model tidak sekadar mengandalkan pola historis, tetapi juga mampu menangkap perubahan signifikan.

Korelasi juga bermanfaat sebagai ukuran ketahanan model dalam jangka panjang. Di tengah volatilitas yang tinggi, kemampuan mempertahankan korelasi yang kuat menjadi indikator bahwa struktur yang digunakan, misalnya kombinasi *CNN-BiGRU-Attention*, mampu menyesuaikan diri terhadap kompleksitas temporal dan variasi fitur data. Hal ini memberi nilai tambah bagi pihak yang memerlukan kestabilan prediksi pada berbagai fase pasar. Hubungan yang kuat antara hasil

prediksi dan harga *IHSG* memperlihatkan bahwa model mampu mengikuti arah pasar dengan baik. Sebaliknya, korelasi yang rendah menjadi pengingat untuk melakukan penyempurnaan. Dengan demikian, korelasi berfungsi tidak hanya sebagai ukuran numerik, tetapi juga sebagai panduan praktis untuk meningkatkan ketepatan penentuan tren pada skala nyata seperti indeks pasar saham.

Performa pada kondisi pasar

Ketika pasar berada pada fase tenang—ditandai dengan fluktuasi harga yang teratur, volatilitas rendah, dan tren berulang yang jelas—model prediksi cenderung menghasilkan kesalahan yang lebih kecil. Pada periode seperti ini, pola historis lebih mudah dikenali sehingga proyeksi harga *Indeks Harga Saham Gabungan (IHSG)* menjadi lebih tepat. Dalam kondisi stabil, jendela waktu yang berfokus pada tren harian atau mingguan sering kali sudah memadai untuk mempertahankan kualitas prediksi. Salah satu alasan utama berkurangnya kesalahan adalah konsistensi pola pergerakan harga. Pada fase ini, perubahan cenderung terjadi secara bertahap dan dapat diantisipasi menggunakan informasi dari periode sebelumnya. Sebagai contoh, jika *IHSG* menunjukkan kenaikan berturut-turut selama beberapa hari dengan volume perdagangan yang konsisten, model dapat menangkap pola tersebut secara lebih efektif tanpa terganggu oleh *noise* atau lonjakan yang tidak terduga.

Kondisi pasar stabil dapat direplikasi melalui proses *backtesting*, yaitu dengan menguji model pada data historis yang mewakili periode tenang. Proses ini memungkinkan penilaian sejauh mana model mampu

mengikuti pola harga IHSG ketika dinamika pasar relatif konstan. Hasilnya memberikan gambaran tentang ketahanan model dalam mengenali tren berulang serta kemampuannya mempertahankan kinerja pada situasi dengan volatilitas minimal.

Pendekatan berbasis model klasik seperti *ARIMA* sering menunjukkan performa baik pada kondisi ini. Karena mengandalkan asumsi bahwa tren historis memegang peranan besar, *ARIMA* cenderung lebih akurat dalam memproyeksikan pergerakan IHSG yang stabil. Namun, model semacam ini mungkin kurang responsif ketika terjadi perubahan tren mendadak akibat faktor eksternal.

Jika performa model justru rendah saat pasar tenang, hal tersebut dapat menjadi indikasi adanya pengaturan yang kurang tepat. Kemungkinan penyebabnya antara lain jendela masukan yang terlalu panjang sehingga menangkap data yang tidak relevan, atau konfigurasi arsitektur seperti ukuran kernel pada *CNN* atau jumlah unit pada *BiGRU* yang belum sesuai untuk menangkap pola stabil. Identifikasi dan penyesuaian terhadap hal-hal ini dapat meningkatkan kemampuan model pada kondisi ideal. Ketika pasar bergerak ke fase yang lebih dinamis—misalnya akibat reaksi terhadap kebijakan ekonomi atau sentimen global—tantangan bagi model meningkat. Kemampuan mempertahankan performa pada kondisi stabil dapat menjadi indikator bahwa model memiliki fondasi yang kuat untuk beradaptasi. Stabilitas hasil pada periode tenang menunjukkan bahwa model tidak hanya belajar dari pola kebetulan, melainkan mampu membangun representasi yang kokoh untuk menghadapi perubahan.

Dengan demikian, fase pasar tenang berperan sebagai momen strategis untuk menguji, mengkalibrasi, dan memperkuat kinerja model.

Model yang dapat menjaga tingkat kesalahan tetap rendah dan prediksi arah yang konsisten pada periode ini akan lebih siap dalam menghadapi periode pasar yang penuh ketidakpastian. Evaluasi yang dilakukan pada situasi ini membantu memastikan bahwa prediksi IHSG dapat diandalkan dalam berbagai kondisi.

Performa pada periode pasar volatil

Periode pasar dengan tingkat volatilitas tinggi dicirikan oleh perubahan harga yang berlangsung cepat dan tajam, baik ke arah kenaikan maupun penurunan. Dalam evaluasi kinerja prediksi harga *Indeks Harga Saham Gabungan (IHSG)*, tingkat volatilitas dapat diperoleh melalui indikator seperti *standard deviation* dari *return*, *average true range (ATR)*, atau *beta* terhadap indeks acuan. Angka volatilitas yang tinggi mencerminkan ketidakstabilan pasar, di mana harga bergerak signifikan dalam waktu singkat, sering kali dipicu oleh berita ekonomi, kebijakan otoritas, atau dinamika global. Situasi ini menjadi tantangan besar bagi model prediksi. Model yang memberikan kinerja baik pada periode stabil kerap mengalami lonjakan kesalahan ketika dihadapkan pada gejolak harga. Sebagai ilustrasi, model *CNN-BiGRU-Attention* yang terbiasa dengan pola IHSG pada fase tenang dapat kehilangan akurasi ketika terjadi lonjakan tajam akibat perubahan suku bunga atau pergerakan nilai tukar. Hal ini dapat disebabkan oleh dominasi *noise* pada data, ketidakmampuan menangkap pergeseran tren yang cepat, atau keterbatasan representasi data periode volatil selama proses pelatihan.

Tingkat kesalahan yang tinggi pada periode volatil juga berkaitan dengan sulitnya mendeteksi *outlier* yang muncul karena transaksi

berskala besar atau sentimen ekstrem. Sebagai contoh, pada awal pandemi COVID-19, IHSG mengalami penurunan tajam diikuti lonjakan dalam waktu singkat, menciptakan data dengan karakter yang sangat berbeda dibanding periode normal. Tanpa kesiapan menghadapi skenario semacam ini, model cenderung kehilangan presisi.

Agar model tetap adaptif pada volatilitas tinggi, sejumlah langkah dapat dilakukan. Pertama, memperpendek jendela waktu masukan sehingga respons terhadap perubahan tren dapat lebih cepat. Kedua, menerapkan teknik *data augmentation* yang meniru pergerakan harga ekstrem untuk memperkaya ragam skenario yang dipelajari. Ketiga, menambahkan fitur seperti indeks volatilitas (*VIX*) atau indikator teknikal jangka pendek guna memberikan wawasan tambahan terhadap gejolak pasar.

Selain itu, pembaruan model secara berkala memiliki peran penting. Penerapan *online learning* atau pembaruan parameter secara real-time membantu mempertahankan kesesuaian model dengan kondisi terkini. Sebagai gambaran, pada periode IHSG yang berayun tajam akibat ketidakpastian geopolitik, pembaruan parameter setiap beberapa hari dapat meningkatkan akurasi prediksi jangka pendek. Pendekatan *ensemble* juga dapat memperkuat ketahanan prediksi, dengan menggabungkan model yang unggul dalam tren jangka panjang dan model yang cepat merespons pergerakan jangka pendek, sehingga tercapai keseimbangan antara sensitivitas dan ketahanan terhadap *noise*. Melalui penerapan langkah-langkah ini, model prediksi harga IHSG berpeluang tetap memberikan informasi yang relevan bagi pengambil keputusan meskipun pasar berada dalam kondisi bergejolak. Adaptasi terhadap volatilitas tidak hanya mempertahankan ketepatan prediksi,

tetapi juga memastikan model tetap menjadi panduan yang andal dalam mengarungi perubahan pasar yang cepat.

Bab 10. Prospek dan Pemanfaatan Model di Masa Depan

Integrasi data tidak Terstruktur

Integrasi data tidak terstruktur, seperti teks dari berita keuangan, pernyataan resmi, dan unggahan publik di media sosial, kini dipandang sebagai sumber informasi yang kaya untuk mendukung prediksi harga *Indeks Harga Saham Gabungan (IHSG)*. Informasi ini membawa sinyal tambahan yang dapat merefleksikan sentimen pasar, persepsi investor, dan ekspektasi terhadap kondisi ekonomi. Melalui penyaringan wacana yang beredar, model dapat mengenali perubahan suasana pasar yang sering kali muncul lebih awal dibandingkan sinyal dari data harga historis. Pendekatan *sentiment analysis* menjadi salah satu cara utama dalam memanfaatkan data jenis ini. Dengan mengelompokkan teks ke dalam kategori positif, negatif, atau netral, model mampu mengaitkan dinamika sentimen dengan kemungkinan arah pergerakan IHSG. Sebagai contoh, meningkatnya pemberitaan positif terkait pertumbuhan ekonomi atau naiknya peringkat kredit nasional kerap diikuti oleh penguatan indeks, sedangkan maraknya berita negatif seperti ketidakpastian politik atau penurunan peringkat investasi cenderung mendorong tekanan jual. Namun, penerapan integrasi data tidak terstruktur menghadirkan sejumlah tantangan. Kualitas teks bervariasi, mulai dari berita resmi yang terverifikasi hingga komentar publik yang sarat *noise*. Penggunaan bahasa yang bias atau bersifat sarkastis di media sosial dapat mengaburkan makna sentimen. Selain itu, volume data yang sangat besar

menuntut kemampuan komputasi yang memadai agar pemrosesan dapat dilakukan secara cepat dan akurat.

Penggunaan teknologi *Natural Language Processing (NLP)* berperan penting untuk menjawab tantangan tersebut. Teknik seperti *tokenization*, *stemming*, dan *word embedding*—misalnya *Word2Vec* atau *BERT*—mengubah kata menjadi representasi vektor numerik yang dapat diolah lebih lanjut. Dalam ranah keuangan, *FinBERT* menawarkan kemampuan memahami istilah spesifik sehingga dapat meningkatkan ketepatan interpretasi sentimen pada teks yang berkaitan langsung dengan IHSG. Integrasi data teks dengan data harga historis IHSG dapat diwujudkan melalui arsitektur hibrid. Model *CNN-BiGRU-Attention* yang sebelumnya dilatih menggunakan data harga dapat diperluas dengan masukan tambahan dari data sentimen, sehingga mampu memadukan sinyal teknikal dan emosional. Contohnya, ketika indikator teknikal menunjukkan tren naik tetapi sentimen publik cenderung negatif, model dapat memberikan prediksi yang lebih waspada.

Pendekatan ini menunjukkan relevansi tinggi dalam momen-momen tertentu. Saat pengumuman stimulus ekonomi berskala besar, berita positif yang mendominasi media dapat meningkatkan kepercayaan investor sehingga mendorong penguatan IHSG. Menggabungkan pembacaan sentimen dari berita dengan pola harga historis dapat memperkuat keyakinan arah pergerakan yang diproyeksikan. Dengan pengolahan yang tepat, integrasi data tidak terstruktur diperkirakan akan semakin berperan dalam memodelkan pergerakan IHSG di masa depan. Sinyal yang diperoleh dari teks berpotensi memberikan peringatan dini terhadap perubahan tren, membantu investor merumuskan keputusan

yang lebih matang, dan memperkaya kemampuan prediksi yang sebelumnya hanya mengandalkan data harga historis.

Pemanfaatan arsitektur deep learning terbaru

Perkembangan dalam *deep learning* telah menghasilkan beragam arsitektur mutakhir yang memperluas kemampuan dalam peramalan deret waktu, termasuk proyeksi harga *Indeks Harga Saham Gabungan (IHSG)*. Salah satu inovasi yang menonjol adalah penggunaan *transformer*, yang awalnya dirancang untuk pemrosesan bahasa alami namun kini banyak diadaptasi untuk mengolah data sekuens finansial. Keunggulan *transformer* terletak pada mekanisme *self-attention* yang dapat memetakan keterhubungan antar titik waktu secara menyeluruh tanpa ketergantungan pada pemrosesan berurutan seperti pada arsitektur *recurrent*. Dibandingkan dengan arsitektur *recurrent* seperti *GRU* atau *LSTM*, *transformer* mampu memproses data secara paralel, sehingga mempercepat proses pembelajaran dan memungkinkan penangkapan pola jangka panjang secara lebih efisien. Dalam penerapannya pada IHSG, hal ini memungkinkan model untuk memahami hubungan antara peristiwa ekonomi yang terpisah jarak waktu namun tetap memengaruhi tren harga. Sebagai contoh, kebijakan moneter yang diumumkan beberapa bulan sebelumnya dapat tetap menjadi variabel penting dalam memproyeksikan pergerakan indeks saat ini.

Meski begitu, arsitektur *recurrent* masih unggul dalam mengidentifikasi dinamika jangka pendek yang bersifat lokal, seperti reaksi cepat pasar terhadap berita harian. Oleh karena itu, tren baru muncul dengan mengombinasikan *transformer* dan modul *recurrent* dalam sebuah desain hibrid. Modul *recurrent* memfokuskan diri pada

perubahan harga intraday atau mingguan, sedangkan *transformer* mengurai keterhubungan jangka panjang antarperiode.

Kombinasi ini dapat diperkuat melalui mekanisme *attention* tambahan yang menyoroti bagian data paling relevan untuk proyeksi. Sebagai ilustrasi, pada data IHSG, modul *recurrent* dapat memproses fluktuasi harga harian, lalu *transformer* memfilter informasi tersebut untuk menonjolkan pola yang sejalan dengan tren bulanan. Pendekatan ini menghasilkan prediksi yang seimbang antara kepekaan terhadap perubahan cepat dan kestabilan terhadap *noise*.

Salah satu contoh implementasi terlihat pada model hibrid yang memanfaatkan *CNN* untuk mengekstraksi fitur lokal dari grafik harga, *GRU* untuk menangani urutan jangka pendek, dan *transformer* untuk mengintegrasikan sinyal historis yang lebih panjang. Dengan rancangan ini, model mampu mengenali formasi teknikal seperti pola *head and shoulders* sambil tetap mempertimbangkan sentimen pasar yang relevan dari periode sebelumnya. Dalam menghadapi karakter IHSG yang kompleks dan dinamis, arsitektur canggih ini memberi peluang untuk meningkatkan ketepatan proyeksi sekaligus memperdalam pemahaman terhadap faktor yang membentuk arah pasar. Sebagai contoh, ketika IHSG berada dalam fase penguatan akibat optimisme global, *transformer* dapat mendeteksi kesamaan pola dengan periode bullish sebelumnya, sedangkan modul *recurrent* memantau potensi pembalikan arah akibat publikasi data ekonomi mingguan.

Ke depan, pengembangan diperkirakan akan mengintegrasikan pemrosesan teks dan citra secara bersamaan, misalnya melalui penggabungan *transformer* harga saham dengan *transformer* analisis berita. Hal ini berpotensi memperkuat kemampuan model untuk

memahami hubungan antara peristiwa aktual dan respons pasar, sehingga memberikan wawasan yang lebih komprehensif bagi pemantauan IHSG.

Adaptasi model untuk pasar dan instrumen keuangan lainnya

Model berbasis *deep learning* yang digunakan untuk memproyeksikan harga *Indeks Harga Saham Gabungan (IHSG)* memiliki keluwesan tinggi untuk diterapkan pada berbagai instrumen keuangan lain seperti komoditas, pasar valuta asing (*forex*), dan obligasi. Rangka kerja yang ada dapat dimanfaatkan kembali dengan melakukan penyesuaian kanal masukan dan cakupan waktu prediksi agar sejalan dengan karakter unik masing-masing pasar. Pendekatan ini memberi keuntungan karena menghemat proses pengembangan dari awal dan tetap mempertahankan kemampuan prediksi yang telah terbentuk. Pasar komoditas seperti minyak mentah atau emas kerap menunjukkan pergerakan yang dipengaruhi oleh dinamika geopolitik dan fluktuasi suplai-permintaan global. Model yang awalnya dibangun untuk IHSG dapat diperkaya dengan kanal masukan tambahan, misalnya indeks harga produsen atau data persediaan komoditas internasional. Di sisi lain, pasar *forex* bergerak responsif terhadap perubahan kebijakan moneter, neraca perdagangan, dan rilis indikator makroekonomi. Penyesuaian jangka waktu prediksi menjadi penting agar model mampu menangkap reaksi pasar mata uang yang sering lebih cepat dan tajam dibandingkan pergerakan indeks saham. Penerapan *transfer learning* membuka peluang untuk mempercepat adaptasi lintas pasar. Bobot yang telah terlatih pada IHSG dapat menjadi landasan awal, memungkinkan model memahami

pola umum perilaku harga sebelum disesuaikan dengan data pasar baru. Sebagai ilustrasi, respons IHSG terhadap pengumuman suku bunga dapat menjadi referensi dalam mengantisipasi pergerakan pasangan mata uang yang menunjukkan reaksi serupa, sehingga proses pembelajaran lebih efisien dan hasil prediksi lebih stabil.

Karakteristik yang berbeda pada setiap pasar menuntut penyesuaian struktur masukan. Tabel penyesuaian lintas instrumen dapat memuat variabel-variabel penting seperti *yield* obligasi pemerintah, indeks keyakinan konsumen, atau indikator teknikal spesifik. Hal ini memastikan informasi yang diproses benar-benar relevan dan memberikan sinyal yang bermakna bagi pengambilan keputusan. Visualisasi penerapan pada pasar mata uang dapat memperlihatkan alur mulai dari pengumpulan kurs harian, pengolahan melalui modul ekstraksi fitur, hingga penggunaan *attention mechanism* untuk menyoroti momen kunci seperti publikasi data inflasi. Prinsip serupa juga dapat digunakan kembali pada IHSG untuk memantau interaksi antara pergerakan nilai tukar rupiah dan pergerakan indeks, misalnya pada periode gejolak kurs. Keterhubungan antar instrumen sangat penting dalam strategi diversifikasi portofolio. Adaptasi lintas pasar memungkinkan pemantau IHSG memperkirakan potensi dampak dari perubahan harga minyak atau fluktuasi nilai tukar terhadap kinerja indeks. Sebagai contoh, penguatan tajam dolar AS dapat dikenali model sebagai potensi tekanan pada IHSG, sehingga membantu perumusan strategi lindung nilai yang tepat. Dengan prinsip adaptasi ini, model yang berawal dari IHSG berpotensi berkembang menjadi alat prediksi multi-instrumen yang andal, memperluas jangkauan pemantauan pasar dan menjaga relevansi prediksi dengan dinamika nyata di berbagai segmen keuangan.

Penggunaan model dalam sistem pendukung keputusan investasi

Pemanfaatan model prediksi berbasis *deep learning* dalam sistem pendukung keputusan investasi menawarkan nilai tambah signifikan, terutama dalam memantau dan mengantisipasi pergerakan *Indeks Harga Saham Gabungan (IHSG)*. Keluaran model dapat dihadirkan dalam beragam bentuk, mulai dari sinyal visual, peringatan dini (*early warning*), hingga rekomendasi kuantitatif yang membantu investor merumuskan langkah strategis. Penyajian informasi yang ringkas, jelas, dan mudah diinterpretasikan menjadi kunci agar keputusan dapat diambil tepat waktu. Integrasi keluaran model ke dalam sistem pendukung keputusan dapat diwujudkan melalui *dashboard* interaktif yang menyajikan indikator utama, tren harga, dan proyeksi jangka pendek maupun jangka panjang. Sebagai contoh, jika model mendeteksi potensi penurunan IHSG akibat tekanan eksternal, sistem dapat memunculkan notifikasi yang disertai ringkasan faktor penyebab yang teridentifikasi. Pendekatan ini memudahkan investor menghubungkan prediksi dengan dinamika pasar yang sedang berlangsung.

Peran desain antarmuka sangat menentukan efektivitas pemanfaatan model. Antarmuka yang intuitif dapat memvisualisasikan keluaran melalui grafik dinamis, *heatmap*, atau kode warna untuk menandai tingkat risiko. Misalnya, zona hijau dapat menunjukkan prediksi kenaikan IHSG yang stabil, sedangkan zona merah mengisyaratkan potensi penurunan signifikan. Representasi visual semacam ini

mempermudah pemahaman tanpa memerlukan analisis mendalam terhadap data mentah.

Otomatisasi dalam sistem pendukung keputusan mampu meningkatkan ketepatan waktu respons. Sistem dengan kemampuan eksekusi otomatis, seperti penyesuaian portofolio berbasis sinyal model, dapat memperpendek jeda antara deteksi peluang atau risiko dan aksi pasar. Contohnya, apabila model memperkirakan lonjakan volatilitas IHSG setelah rilis data ekonomi global, sistem dapat mengirim instruksi penyesuaian portofolio secara langsung ke broker sesuai parameter yang telah ditentukan. Meskipun demikian, otomatisasi perlu dilengkapi dengan kontrol manual. Investor sebaiknya tetap memiliki kesempatan meninjau rekomendasi sebelum dieksekusi, guna memastikan kesesuaian dengan profil risiko masing-masing. Dukungan *audit trail* yang mencatat setiap sinyal dan rekomendasi juga bermanfaat untuk evaluasi efektivitas model dalam jangka panjang.

Hubungan antara keluaran model dan IHSG dapat dimanfaatkan untuk menyusun simulasi skenario. Sebagai ilustrasi, sistem dapat memproyeksikan dampak perubahan suku bunga atau harga komoditas global terhadap IHSG pada periode mendatang, sehingga investor dapat merancang strategi mitigasi risiko secara lebih matang. Fitur ini memperluas wawasan pengguna dan meningkatkan kesiapan menghadapi gejolak pasar. Dengan pengemasan yang tepat, model prediksi berperan bukan hanya sebagai alat bantu teknis, tetapi juga sebagai bagian integral dari ekosistem pengambilan keputusan investasi modern. Perpaduan akurasi model, antarmuka yang ramah pengguna, dan otomatisasi yang adaptif mampu memberikan keunggulan kompetitif bagi pengelola portofolio di pasar saham, khususnya IHSG.

Arah pengembangan menuju prediksi real-time

Pengembangan model prediksi menuju *real-time forecasting* menjadi langkah strategis yang memperkuat relevansi informasi bagi pelaku pasar. Dalam penerapannya pada *Indeks Harga Saham Gabungan (IHSG)*, kemampuan menyajikan hasil seketika setelah data diterima memberikan keunggulan yang signifikan, terutama ketika harga bergerak cepat. Pemrosesan dengan latensi rendah memungkinkan investor merespons perubahan sebelum momentum berlalu. Mendukung *real-time forecasting* membutuhkan kombinasi komputasi berperforma tinggi, konektivitas data yang stabil, dan sistem terdistribusi. Pemanfaatan *cloud computing* dan *edge computing* mempercepat aliran data dari sumber pasar menuju modul pemrosesan. Contohnya, data perdagangan IHSG yang diambil langsung dari *feed* bursa dapat melewati *pipeline* otomatis yang dioptimalkan, kemudian diproses oleh model tanpa hambatan berarti.

Menekan latensi menjadi prioritas agar keluaran tetap relevan. Teknik seperti *stream processing* dan optimisasi *inference engine* pada perangkat keras khusus seperti *GPU* atau *TPU* mempersingkat waktu pemrosesan. Penyesuaian *batch size* dan penerapan *model quantization* juga dapat mempercepat prediksi tanpa mengorbankan ketepatan. Misalnya, dalam strategi perdagangan frekuensi tinggi, keterlambatan sekecil apa pun saat memproses pembaruan harga IHSG setiap detik dapat memengaruhi hasil akhir. Penerapan *real-time model deployment* di keuangan sering terlihat pada *algorithmic trading* yang menggunakan data langsung untuk eksekusi otomatis. Pada IHSG, model dapat memicu sinyal beli saat pola tertentu terdeteksi pada grafik intraday, atau sinyal

jual ketika lonjakan volume diikuti penurunan harga secara tajam. Kecepatan reaksi dalam hitungan detik menjadi faktor pembeda dalam memanfaatkan peluang.

Selain sisi teknis, integrasi *real-time forecasting* ke dalam sistem pendukung keputusan investasi memerlukan antarmuka yang menyajikan informasi secara ringkas dan jelas. Visualisasi seperti *ticker* harga dengan indikator arah prediksi, peta panas sektor, atau grafik interaktif dengan pembaruan otomatis membantu pengguna menangkap sinyal tanpa harus menghentikan aktivitas utama mereka. Misalnya, manajer investasi dapat memantau prediksi IHSG lima menit ke depan beserta tingkat keyakinan model untuk menyesuaikan portofolio. Kemampuan *real-time* juga memungkinkan penyesuaian adaptif secara langsung. Sistem dapat memperbarui parameter berdasarkan kinerja prediksi sebelumnya, menjaga kepekaan terhadap kondisi pasar yang berubah. Sebagai contoh, saat volatilitas IHSG meningkat karena pengumuman kebijakan ekonomi, bobot variabel dalam model dapat diubah untuk memperkuat respons terhadap pergerakan harga intraday. Dengan infrastruktur yang baik, latensi rendah, dan integrasi yang terencana, pengembangan ke arah prediksi *real-time* memberikan nilai tambah yang nyata. Bagi investor IHSG, hal ini bukan hanya mempercepat pengambilan keputusan, tetapi juga memperkuat strategi manajemen risiko dalam menghadapi perubahan pasar yang dinamis.

DAFTAR PUSTAKA

- Abgeena, A., & Garg, S. (2023). A novel convolution bi-directional gated recurrent unit neural network for emotion recognition in multichannel electroencephalogram signals. *Technology and Health Care*, 31(4), 1215–1234. <https://doi.org/10.3233/thc-220458>
- Alexander, A., & Beegam, S. (2023). Modeling symmetric and asymmetric volatility in Nifty 50 index futures market. *CBR*, 15(1), 89–102. <https://doi.org/10.59640/cbr.v15i1.89-102>
- Amalia, F. (2022). The impact of COVID-19 outbreak on Indonesia tourism stock performance. *Jurnal Industri Pariwisata*, 5(1), 79–89. <https://doi.org/10.36441/pariwisata.v5i1.988>
- Bohyer, K., & Hayajneh, T. (2023). Modernizing contracts across industries: A review of smart contract applications and the evolving legal landscape. *ICST Transactions on Scalable Information Systems*. <https://doi.org/10.4108/eetsis.3299>
- Chen, C., Hung, S., Chen, P., Wang, C., & Chiang, R. (2023). A memetic-based technical indicator portfolio and parameters optimization approach for finding trading signals to construct transaction robot in smart city era. *Intelligent Data Analysis*, 27(5), 1433–1456. <https://doi.org/10.3233/ida-220755>
- Chen, Y., Ng, J., & Yang, X. (2021). Talk less, learn more: Strategic disclosure in response to managerial learning from the options market. *Journal of Accounting Research*, 59(5), 1609–1649. <https://doi.org/10.1111/1475-679x.12368>
- Dai, L., & Wang, H. (2024). An improved WOA (whale optimization algorithm)-based CNN-BiGRU-CBAM model and its application to short-term power load forecasting. *Energies*, 17(11), 2559. <https://doi.org/10.3390/en17112559>
- Duxbury, D., & Wang, W. (2023). Investor sentiment and the risk–return relation: A two-in-one approach. *European Financial Management*, 30(1), 496–543. <https://doi.org/10.1111/eufm.12427>
- Eslamieh, P., Shajari, M., & Nickabadi, A. (2023). User2Vec: A novel representation for the information of the social networks for stock market prediction using convolutional and recurrent neural networks. *Mathematics*, 11(13), 2950. <https://doi.org/10.3390/math11132950>
- Gabaix, X., & Koijen, R. (2021). In search of the origins of financial fluctuations: The inelastic markets hypothesis. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3875134>
- Gao, Z., & Kuruoğlu, E. (2023). Attention based hybrid parametric and neural network models for non-stationary time series prediction. *Expert Systems*, 41(2). <https://doi.org/10.1111/exsy.13419>

- Gu, G. (2023). The dynamic interplay of market forces and human behavior: A critical review of efficient market hypothesis and behavioral finance. *Advances in Economics, Management and Political Sciences*, 31(1), 54–59. <https://doi.org/10.54254/2754-1169/31/20231498>
- Han, Q., Zhao, C., Chen, J., & Guo, Q. (2022). Reexamining the impact of closing call auction on market quality: A natural experiment from the Shanghai Stock Exchange. *Pacific-Basin Finance Journal*, 74, 101821. <https://doi.org/10.1016/j.pacfin.2022.101821>
- Huang, C., Zhao, T., Huang, D., Cen, B., Zhou, Q., & Chen, W. (2024). Artificial intelligence-based power market price prediction in smart renewable energy systems: Combining Prophet and transformer models. *Heliyon*, 10(20), e38227. <https://doi.org/10.1016/j.heliyon.2024.e38227>
- Hung, N. (2023). Forecasting the Vietnamese stock market using technical analysis indicators. *International Journal of Management & Entrepreneurship Research*, 5(12), 1076–1084. <https://doi.org/10.51594/ijmer.v5i12.657>
- Indah, Y., & Mahyuni, L. (2022). The accuracy of relative strength index (RSI) indicator in forecasting foreign exchange price movement. *Inovbiz: Jurnal Inovasi Bisnis*, 10(1), 96. <https://doi.org/10.35314/inovbiz.v10i1.2249>
- Jiang, C., Sun, X., Dai, Y., Zhang, Y., Chen, D., Li, Y., ... & Tang, Y. (2024). EEG emotion recognition employing RGPCN-BiGRUAM: ReliefF-based graph pooling convolutional network and BiGRU attention mechanism. *Electronics*, 13(13), 2530. <https://doi.org/10.3390/electronics13132530>
- Kaushik, M., & Kumar, N. (2023). GDP's (gross domestic product) impact on stock market movement in India: A study on BSE Sensex. *International Journal of Research in Finance and Management*, 6(1), 152–156. <https://doi.org/10.33545/26175754.2023.v6.i1b.207>
- Kexin, H., & Zhang, Z. (2022). Prediction stock price based on CNN and LSTM models. *Financial Engineering and Risk Management*, 5(7). <https://doi.org/10.23977/ferm.2022.050703>
- Klaar, A., Stefenon, S., Seman, L., Mariani, V., & Coelho, L. (2023). Optimized EWT-seq2seq-LSTM with attention mechanism to insulators fault prediction. *Sensors*, 23(6), 3202. <https://doi.org/10.3390/s23063202>
- Lastauskas, P., & Minh, A. (2021). Global impacts of US monetary policy uncertainty shocks. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3797133>
- Lerner, P. (2022). Fourier integral operator model of market liquidity: The Chinese experience 2009–2010. *Mathematics*, 10(14), 2459. <https://doi.org/10.3390/math10142459>
- Li, C., Shen, L., & Qian, G. (2023). Online hybrid neural network for stock price prediction: A case study of high-frequency stock trading in the Chinese market. *Econometrics*, 11(2), 13. <https://doi.org/10.3390/econometrics11020013>

- Li, Y., Chen, L., Sun, C., Liu, G., Chen, C., & Zhang, Y. (2024). Accurate stock price forecasting based on deep learning and hierarchical frequency decomposition. *IEEE Access*, 12, 49878–49894. <https://doi.org/10.1109/access.2024.3384430>
- Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: A survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2194), 20200209. <https://doi.org/10.1098/rsta.2020.0209>
- Lim, S. (2024). The efficacy of relative strength index (RSI) in KLSE market trade. *Issues and Perspectives in Business and Social Sciences*, 4(2), 108–114. <https://doi.org/10.33093/ipbss.2024.4.2.1>
- Lin, C., Chiang, K., Lee, M., & Lee, Y. (2021). The cross-border price discovery and the Shanghai–Hong Kong Stock Connect. *Asian Journal of Economics and Finance*, 13–28. <https://doi.org/10.47260/amae/1132>
- Liu, Y., & Pan, B. (2024). Profit estimation model and financial risk prediction combining multi-scale convolutional feature extractor and BGRU model. *Informatica*, 48(11). <https://doi.org/10.31449/inf.v48i11.5941>
- Liu, Y., Zhao, C., & Huang, Y. (2022). A combined model for multivariate time series forecasting based on MLP-feedforward attention-LSTM. *IEEE Access*, 10, 88644–88654. <https://doi.org/10.1109/access.2022.3192430>
- Mahmoudabadi, A., Kanaani, M., & Ghazimahalleh, F. (2022). Modifying hidden layer in neural network models to improve prediction accuracy: A combined model for estimating stock price. *HighTech and Innovation Journal*, 3(1), 45–55. <https://doi.org/10.28991/hij-2022-03-01-05>

Biodata Penulis



Ibnu Rasyid Munthe, ST., M.Kom., lahir di Rantau Prapat, Kabupaten Labuhanbatu, pada 1987. Beliau menyelesaikan pendidikan S1 di Universitas Nurtanio Bandung dan S2 di Universitas Putra Indonesia (YPTK) Padang. Aktif menulis artikel ilmiah dan buku, Ibnu Rasyid Munthe saat ini mengajar di Universitas Labuhanbatu. Selain itu, beliau mengelola kanal YouTube @manjaddawajada2022 sebagai media pembelajaran dan berbagi pengetahuan, memberikan kontribusi dalam dunia pendidikan dan teknologi.



Bhakti Helvi Rambe, SE., M.Si., lahir di Rantauprapat pada 28 September 1988, adalah sosok akademisi inspiratif yang memadukan dedikasi, pengetahuan, dan ketulusan dalam setiap langkahnya. Tumbuh di tanah kelahiran yang membentuk karakter gigih, ia menempuh pendidikan dasar hingga menengah di SD, MTsN, dan SMA Rantauprapat. Kecintaan mendalam pada ekonomi dan akuntansi mengantarkannya meraih gelar Sarjana dan Magister Akuntansi di Universitas Sumatera Utara. Memulai karier mengajar di LP3M Medan, kini ia menjadi dosen tetap di Fakultas Ekonomi dan Bisnis Universitas Labuhanbatu. Dengan semangat membimbing, ia terus menginspirasi generasi muda melalui ilmu dan teladan..



Shabrina Rasyid Munthe, S.Pd.I., MS, lahir di Rantauprapat pada 20 Februari 1992. Beliau meraih gelar S1 di bidang Tarbiyah dari Institut Agama Islam Negeri Padangsidempuan dan S2 Magister Sastra dari Universitas Islam Sumatera Utara (UISU). Sejak 2019, beliau menjabat dosen tetap di Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Al Washliyah Labuhanbatu. Shabrina juga aktif berkontribusi dalam pengembangan ilmu pengetahuan dan pendidikan, khususnya di bidang bahasa Inggris.



Selamat Subagio, S.Kom., M.Kom., lahir di Rantauprapat, Kabupaten Labuhanbatu, Sumatera Utara, pada 13 Juni 1980. Menyelesaikan pendidikan Sarjana di STMIK AKAKOM Yogyakarta, ia memperdalam keahliannya di bidang Sistem Informasi melalui studi Magister di UPI–YTPK Padang. Saat ini, ia mengabdikan sebagai dosen di Fakultas Ilmu Komputer, Prodi Teknik Informatika Universitas Al Washliyah Labuhanbatu. Berpengalaman luas di bidang software & hardware, artificial intelligence, RDBMS, sistem informasi, expert system, database server, dan decision support system, ia dikenal sebagai pendidik yang memadukan wawasan teknologi mutakhir dengan semangat membimbing generasi muda. Email: ssubagio1306@gmail.com.



Rahmad Aditiya, lahir di Perdamean, Rantau Selatan, Labuhanbatu pada 15 Agustus 1990, adalah pakar Teknologi Informasi dengan keahlian di IT Support, analisis data, konsultasi TI, dan keamanan siber. Menyelesaikan S1 di Universitas Al Washliyah Labuhanbatu dan S2 di Universitas Putra Indonesia

YPTK Padang, ia memiliki pengalaman lebih dari lima tahun sebagai dosen. Selain mengajar, ia aktif sebagai Konsultan IT dan pernah menjabat Kepala Divisi IT di berbagai perusahaan. Dedikasinya tercermin dalam berbagai proyek teknologi strategis. Saat ini berdomisili di Rantau Selatan, ia dapat dihubungi melalui email: ayitida15@gmail.com.



Eko Firman Susilo, M.Pd., lahir di Dusun Siluman, Kecamatan Bilah Barat, Kabupaten Labuhanbatu, Sumatera Utara, pada 3 Mei 1993. Ia meraih gelar Sarjana di Universitas Al-Washliyah Labuhanbatu (UNIVA) dan melanjutkan Magister di Universitas Negeri Medan (UNIMED) dengan bidang keahlian

Pendidikan Bahasa dan Sastra Indonesia. Saat ini, ia mengabdikan sebagai dosen tetap di UNIVA, membimbing mahasiswa dengan dedikasi dan kecintaan pada bahasa. Keahliannya dalam mengajar disertai komitmen untuk mengembangkan literasi akademik di lingkungan kampus. Untuk kolaborasi atau diskusi akademik, ia dapat dihubungi melalui email: ekofirmansusilo949@gmail.com.

Ringkasan Buku

Pasar saham adalah medan dinamis yang penuh peluang sekaligus risiko. Di tengah volatilitas dan kompleksitasnya, kemampuan memprediksi pergerakan harga secara akurat menjadi kunci bagi investor, manajer aset, dan regulator. Buku monograf ini menghadirkan inovasi pemodelan prediksi saham berbasis CNN-BiGRU yang dipadukan dengan Attention Mechanism—mengkombinasikan kekuatan CNN dalam menangkap pola spasial, BiGRU dalam memahami hubungan temporal dua arah, serta Attention untuk memfokuskan analisis pada informasi paling relevan. Buku ini diawali dengan landasan teori pergerakan harga saham, meliputi faktor ekonomi, psikologis, teknikal, siklus pasar, dan volatilitas. Selanjutnya, dibahas perbandingan pendekatan konvensional dengan teknologi modern berbasis AI, yang mampu mengatasi tantangan data non-linear dan tidak stasioner.

Pembaca diajak memahami arsitektur deep learning untuk data time series, strategi pengolahan dan rekayasa fitur, hingga teknik pelatihan model yang efektif menghindari overfitting. Penerapan mekanisme attention dijelaskan melalui studi kasus prediksi harga saham, lengkap dengan evaluasi kinerja dan interpretasi hasil. Buku ini tidak hanya menawarkan pengetahuan akademis, tetapi juga panduan praktis untuk mengintegrasikan model prediksi dalam pengambilan keputusan investasi, manajemen risiko, dan pengembangan strategi pasar. Dengan bahasa yang sistematis dan didukung data empiris, karya ini relevan bagi akademisi, praktisi pasar modal, mahasiswa, maupun pengembang teknologi keuangan yang ingin memanfaatkan kekuatan AI untuk meningkatkan akurasi dan ketepatan keputusan investasi. Hadirnya buku ini diharapkan menjadi pijakan strategis dalam menciptakan ekosistem pasar modal yang lebih adaptif, presisi, dan berkelanjutan di era informasi cepat dan data besar.

Pasar saham adalah ekosistem dinamis yang penuh peluang sekaligus risiko. Fluktuasi harga yang tampak acak sebenarnya menyimpan pola tersembunyi, yang hanya dapat diungkap melalui pendekatan analisis cerdas. Buku ini menghadirkan inovasi pemodelan prediksi saham berbasis kombinasi **Convolutional Neural Network (CNN)** untuk mengidentifikasi pola spasial, **Bidirectional Gated Recurrent Unit (BiGRU)** untuk menangkap hubungan temporal dua arah, serta **Attention Mechanism** untuk memfokuskan analisis pada informasi paling relevan.

Disusun dengan pendekatan ilmiah sekaligus aplikatif, buku ini mengupas fondasi pergerakan harga saham, perbandingan metode klasik dan berbasis AI, arsitektur model deep learning untuk data pasar, teknik rekayasa fitur, hingga strategi evaluasi kinerja prediksi. Setiap bab dilengkapi contoh penerapan nyata dan penjelasan teknis yang dapat diikuti oleh akademisi, praktisi pasar modal, maupun mahasiswa yang ingin menguasai teknologi prediksi mutakhir.

Lebih dari sekadar teori, buku ini mengajarkan bagaimana memanfaatkan teknologi AI untuk mengantisipasi perubahan pasar, mengelola risiko, dan meningkatkan ketepatan keputusan investasi. Sebuah panduan strategis bagi siapa saja yang ingin memadukan kecerdasan buatan dengan intuisi investasi, demi meraih peluang terbaik di tengah volatilitas pasar global.

