

Gated Recurrent Unit **dan Indeks Harga Saham Gabungan**

Rizki Baehtiar Afandi
I Gede Susrama Mas Diyasa



PT. GHANI PRESS GROUP

***Gated Reccurent Unit* dan Indeks Harga Saham Gabungan**

Penulis:

Rizki Baehtiar Afandi | I Gede Susrama Mas Diyasa

Desain Cover:

Umar Khasan

Layouter:

Tyas Dzawil Istiqomah

Editor Naskah:

Retno Mumpuni

14 x 21 cm, v-96

ISBN: 978-634-97192-4-7

Anggota IKAPI: No. 468/JTI/2026

Diterbitkan oleh: PT GHANI PRESS GROUP

Alamat:

Bumi Permata Raya Blok 8 No. 14 Tanjung, Lamongan

HP. 0896-5710-0105

Email: ptghanipress@gmail.com

Website: <https://ghanipress.com/>

© Hak Cipta 2026 pada penulis

Sanksi Pelanggaran Pasal 113

Undang-Undang No. 28 Tahun 2014 Tentang Hak Cipta

- a. Setiap Orang yang dengan tanpa hak melakukan pelanggaran hak ekonomi sebagaimana dimaksud dalam Pasal 9 ayat (1) huruf i untuk Penggunaan Secara Komersial dipidana dengan pidana penjara paling lama 1 (satu) tahun dan/atau pidana denda paling banyak Rp 100.000.000 (seratus juta rupiah).
- b. Setiap Orang yang dengan tanpa hak dan/atau tanpa izin Pencipta atau pemegang Hak Cipta melakukan pelanggaran hak ekonomi Pencipta sebagaimana dimaksud dalam Pasal 9 ayat (1) huruf c, huruf d, huruf f, dan/atau huruf h untuk Penggunaan Secara Komersial dipidana dengan pidana penjara paling lama 3 (tiga) tahun dan/atau pidana denda paling banyak Rp 500.000.000,00 (lima ratus juta rupiah).
- c. Setiap Orang yang dengan tanpa hak dan/atau tanpa izin Pencipta atau pemegang Hak Cipta melakukan pelanggaran hak ekonomi Pencipta sebagaimana dimaksud dalam Pasal 9 ayat (1) huruf a, huruf b, huruf e, dan/atau huruf g untuk Penggunaan Secara Komersial dipidana dengan pidana penjara paling lama 4 (empat) tahun dan/atau pidana denda paling banyak Rp 1.000.000.000,00 (satu miliar rupiah).
- d. Setiap Orang yang memenuhi unsur sebagaimana dimaksud pada ayat (3) yang dilakukan dalam bentuk pembajakan, dipidana dengan pidana penjara paling lama 10 (sepuluh) tahun dan/atau pidana denda paling banyak Rp 4.000.000.000,00 (empat miliar rupiah).

KATA PENGANTAR

Puji syukur kehadiran Tuhan Yang Maha Esa, karena atas rahmat dan karunia-Nya buku yang berjudul “***Gated Recurrent Unit dan Indeks Harga Saham Gabungan***” ini dapat diselesaikan dengan baik. Buku ini disusun sebagai upaya memberikan kontribusi ilmiah dalam pengembangan metode prediksi pasar modal yang lebih akurat dan berbasis teknologi mutakhir.

Indeks Harga Saham Gabungan (IHSG) memiliki pergerakan yang sangat dinamis dan volatil, sehingga seringkali memicu ketidakpastian di pasar finansial. Kondisi tersebut menuntut adanya pendekatan prediksi modern. Buku ini hadir untuk mengulas pemanfaatan teknologi *Deep Learning*, khususnya model *Gated Recurrent Unit* (GRU), dalam menangkap pola data deret waktu secara lebih presisi.

Akhir kata semoga buku ini bermanfaat bagi para mahasiswa, dosen, peneliti, dan pengamat pasar modal dan juga masyarakat secara luas.

Surabaya, Juli 2026

Penulis

DAFTAR ISI

KATA PENGANTAR	v
DAFTAR ISI	vii
BAB I	
Pendahuluan	1
BAB II	
Indeks Harga Saham Gabungan.....	7
BAB III	
<i>Gated Reccurent Unit</i>	19
BAB IV	
Contoh Aplikasi Model GRU	59
BAB V	
Performa dan Konfigurasi Optimal Model	75
DAFTAR PUSTAKA	81
BIODATA PENULIS	95

BAB I

Pendahuluan

Pasar saham menjadi salah satu sarana investasi yang paling diminati diseluruh dunia, termasuk di negara Indonesia. Hal ini disebabkan oleh potensi keuntungan yang dapat diperoleh melalui *capital gain* maupun dividen, serta memiliki kemudahan akses yang ditawarkan oleh teknologi informasi. Bursa Efek Indonesia (BEI) memiliki fungsi untuk sarana bagi para investor dalam melakukan aktivitas perdagangan saham dari perusahaan yang telah terdaftar di pasar modal. Hingga awal tahun 2025, jumlah investor pasar modal di Indonesia telah tercatat mencapai sekitar 15 juta, sehingga mencerminkan meningkatnya ke-tertarikan masyarakat terhadap saham sebagai salah satu instrumen investasi jangka panjang [1].

Indeks Harga Saham Gabungan (IHSG) merupakan salah satu indikator penting yang digunakan dalam menunjukkan kondisi serta pergerakan kinerja dari pasar modal di Indonesia. Sebagai indikator yang sangat komprehensif, IHSG mengakumulasi nilai seluruh saham yang terdaftar di BEI, sehingga memiliki peran penting dalam membantu investor dalam pengambilan keputusan investasi dan juga memberikan cerminan kesehatan perekonomian nasional. Sepanjang tahun 2025, IHSG mencatatkan rekor nilai tertinggi pada nilai 7.543,503 yang terjadi pada penutupan perdagangan tanggal 25 Juli 2025. Kenaikan ini mencerminkan performa positif pasar saham Indonesia di tengah tantangan ekonomi global. IHSG mengalami kenaikan mingguan sebesar 3,17% dibandingkan minggu sebelumnya. Hal ini menunjukkan bahwa sentimen positif terus berkembang di kalangan investor, yang semakin percaya terhadap prospek pasar modal di Indonesia [2].

Pergerakan IHSG juga sering kali menunjukkan fluktuasi yang signifikan, baik dalam bentuk peningkatan maupun penurunan yang cukup tajam, hal ini biasanya dipengaruhi oleh berbagai faktor, antara lain kondisi ekonomi, situasi politik, serta sentimen pasar yang terus berubah [3], [4]. Kondisi fluktuasi tersebut menjadikan kegiatan prediksi harga saham sebagai tantangan yang kompleks, terutama bagi investor yang ingin mengambil keputusan investasi secara rasional dan berbasis data. Tingkat akurasi dalam memprediksi harga saham tidak hanya memberikan peluang untuk memperoleh keuntungan, tetapi juga berperan dalam mengurangi potensi kerugian yang disebabkan oleh dinamika pasar.

Adi & Ismawati (2023) harga emas dunia dan Indeks DJIA (*Dow Jones Industrial Average*) memiliki pengaruh terhadap perkembangan harga IHSG. Secara lebih spesifik, harga emas dunia dan Indeks DJIA berpengaruh secara parsial terhadap IHSG pada periode 2017-2021 yang diteliti [5]. Purwaningsih & Sriyono. (2023) faktor ekonomi nilai tukar rupiah

berpengaruh secara signifikan terhadap IHSG, sedangkan inflasi dan produk domestik bruto (PDB) tidak menunjukkan pengaruh yang signifikan terhadap IHSG [6].

Yusuf (2021) algoritma *Long Short-Term Memory (LSTM)* digunakan untuk memprediksi pergerakan harga saham IHSG. LSTM mampu memberikan performa model yang baik dalam menangkap pola *time series* IHSG [7].

Rahmadeyan & Mustakim, (2024) menggunakan algoritma *Long Short-Term Memory dan Gated Recurrent Unit* untuk memprediksi harga saham Bank Rakyat Indonesia dari 1 Januari 2018 sampai 30 Desember 2022. Model diuji menggunakan Skenario pengujian timesteps, Optimizer, Batch Size, dan *Learning Rate*. Model GRU terbaik didapatkan pada skenario pengujian Timesteps 30, *Optimizer* RMSDrop, Batch Size 32, dan *Learning Rate* 0.0001. Model GRU menjadi model terbaik daripada LSTM dengan mendapatkan nilai terendah MSE 4958,9168, RMSE 70,4195, dan MAPE 1,1699% [8]. Model GRU

mampu untuk memprediksi harga saham dengan lebih baik daripada LSTM.

Saud & Shakya (2020) mereka menggunakan algoritma LSTM dan GRU untuk memprediksi harga saham Nepal Investment Bank Limited (NIB) dan Nabil Bank Limited (NABIL). Mereka menggunakan pengukuran nilai evaluasi menggunakan MAPE. Model akan dilakukan analisis menggunakan skenario pengujian panjang periode loop-back. Model LSTM menjadi model terbaik saat menggunakan loopback 2 dan 5 dengan mendapatkan nilai MAPE sekitar 1,9%-2,5% untuk saham NABIL, sedangkan saham NIB mendapatkan nilai MAPE sekitar 4%-5%. Model GRU menjadi model terbaik saat menggunakan loop-back 10 hingga 30 dengan mendapatkan nilai MAPE sekitar 4%-5,9% untuk saham NABIL, sedangkan saham NIB mendapatkan nilai MAPE sekitar 4%-5% [9]. Hasil ini menjelaskan bahwa model GRU baik jika digunakan untuk loop-back besar.

BAB II

Indeks Harga Saham Gabungan

➤ Saham

Saham merupakan alat keuangan yang dipakai untuk menunjukkan kepemilikan seseorang atau entitas terhadap suatu perusahaan dan memberikan hak atas sebagian keuntungan (dividen) serta potensi *capital gain* dari suatu kenaikan harga saham di pasar modal. Purba (2017), saham dapat diartikan sebagai surat berharga yang menjadikan bagikan kepemilikan dalam perusahaan dan menjadi salah satu bentuk investasi yang paling likuid di pasar keuangan global [10]. Pergerakan harga saham dapat dipengaruhi oleh berbagai faktor, faktor internal perusahaan seperti kinerja keuangan, struktur modal, dan kebijakan dividen. Faktor eksternal pergerakan saham seperti kondisi ekonomi makro, kebijakan moneter, nilai

tukar, serta sentimen pasar [11]. Dalam konteks pasar berkembang (*emerging markets*) seperti di negara Indonesia, karakteristik saham cenderung lebih volatil karena dipengaruhi oleh tingkat ketidakpastian ekonomi dan sensitivitas terhadap perubahan global [12].

Saham memiliki peran penting dalam mendukung pertumbuhan ekonomi nasional karena pasar saham berfungsi sebagai sarana penghimpunan dana dari masyarakat yang kemudian digunakan untuk membiayai berbagai kegiatan produktif perusahaan [13]. Fahrini dkk. (2024), pasar saham yang efisien dapat mencerminkan informasi fundamental secara cepat ke dalam harga saham, sehingga akan menjadi indikator penting dalam stabilitas ekonomi [14]. Namun demikian, pergerakan harga saham tidak hanya dipengaruhi oleh faktor rasional semata, tetapi juga oleh perilaku investor serta ekspektasi mereka terhadap kondisi perekonomian [15]. Faktor psikologis dan konteks ekonomi tersebut akan membentuk keputusan

investasi di pasar modal, tidak dari sekedar analisis keuangan perusahaan.

Berdasarkan sudut pandang hak tagih saham dapat dibedakan menjadi saham biasa (*common stock*) dan saham preferen (*preferred stock*). Saham biasa merupakan surat berharga yang memberikan hak kepemilikan serta hak suara dalam rapat umum kepada pemegang saham. Selain itu, pemegang saham juga berhak memperoleh keuntungan dalam bentuk dividen dan *capital gain* yang nilainya cenderung fluktuatif tergantung pada kinerja perusahaan. Sementara itu, saham preferen memiliki sifat gabungan dari obligasi dan saham, pemilik saham akan mendapatkan keuntungan tetap berupa dividen dan memiliki prioritas dalam pembagian hasil usaha. Namun, pemilik saham preferen tidak akan memiliki hak suara dalam pengambilan keputusan perusahaan. Dividen merupakan bagian keuntungan perusahaan yang dibagikan kepada para pemegang saham sebagai bentuk imbal hasil atas kepemilikan modal. Berdasarkan bentuk pembayarannya, dividen dapat

diklasifikasikan menjadi tiga jenis, yaitu dividen tunai (*cash dividend*), dividen properti (*property dividend*), dan dividen likuidasi (*liquidating dividend*). Dividen tunai adalah pembagian keuntungan berupa uang tunai yang akan selalu dibayarkan pada periode tertentu sesuai keuntungan atau laba yang diperoleh perusahaan. Dividen properti akan membagikan keuntungan dalam bentuk aset atau barang. Dividen likuidasi adalah memberikan kekayaan perusahaan kepada pemegang saham, apabila perusahaan mengalami likuidasi atau pembubaran. Ketiga bentuk dividen ini mencerminkan kebijakan perusahaan dalam mengelola keuntungan dan menjaga kepercayaan para investor terhadap kinerja keuangan yang dimilikinya [16].

➤ Indeks Harga Saham Gabungan (IHSG)

Indeks Harga Saham Gabungan (IHSG) merupakan indikator utama yang merepresentasikan kondisi pasar modal di Indonesia, di mana pergerakannya dipengaruhi oleh berbagai faktor baik domestik

maupun global [17]. Kebijakan moneter seperti suku bunga BI, nilai tukar rupiah, serta ketidakpastian global yang tercermin dari indeks pasar saham luar negeri seperti *Dow Jones Industrial Average* dapat memberikan pengaruh signifikan terhadap fluktuasi IHSG. Putra dkk. (2024) BI Rate, nilai tukar rupiah, dan indeks *Dow Jones* memiliki pengaruh signifikan terhadap penurunan IHSG, sedangkan inflasi tidak selalu berpengaruh terhadap harga IHSG [18]. Hal ini menjelaskan bahwa perubahan kondisi ekonomi global dan kebijakan moneter domestik akan memiliki hubungan erat dalam menentukan arah pergerakan harga IHSG di pasar modal Indonesia.

Selain faktor makroekonomi, perilaku dan psikologi dari investor juga akan berpengaruh signifikan terhadap pergerakan IHSG. Rahmawati dkk. (2023) *loss aversion* bias dan tingkat literasi keuangan dapat mempengaruhi keputusan investasi, terutama pada generasi muda atau biasa disebut gen Z. Literasi keuangan akan berperan pada dampak penurunan IHSG sebagai faktor moderasi sebagai keputusan

investasi [19]. Ketidakpastian politik, kebijakan fiskal yang tidak konsisten, dan isu ekonomi global juga sering kali akan menurunkan kepercayaan investor, sehingga akan memperlemah kinerja IHSG. Aman dkk. (2024) pertumbuhan ekonomi (*GDP growth*) serta guncangan eksternal (*global shocks*) merupakan determinan utama dan paling sering dikaitkan dengan fluktuasi harga IHSG [20].

➤ ***Dow Jones Industrial Average***

Dow Jones Industrial Average (DJIA) adalah salah satu indeks saham paling tua dan paling berpengaruh di dunia. DJIA akan mencerminkan kinerja dari 30 perusahaan besar di Amerika Serikat yang mewakili sektor industri utama di sana. Indeks DJIA banyak digunakan sebagai indikator utama dalam menilai kesehatan ekonomi global, karena indeks ini mencerminkan tingkat kepercayaan investor terhadap pasar saham Amerika Serikat [21]. Pergerakan indeks DJIA dipengaruhi oleh berbagai faktor makroekonomi, seperti inflasi dan suku bunga

jangka pendek, serta perubahan variabel pasar saham konvesinonal (return dan volatilitas indeks saham lain) [22].

Latif dkk. (2024) DJIA memiliki pengaruh yang signifikan terhadap pergerakan IHSG [23]. Bakthiar & Purwani (2021) kenaikan dari harga DJIA sering diikuti oleh peningkatan harga IHSG karena investor merasa optimis yang merespon kondisi positif di pasar global [24]. DJIA merupakan variabel global yang paling konsisten memengaruhi harga IHSG di tengah ketidakpastian ekonomi dunia. Penjelasan sebelumnya menguatkan bahwa DJIA tidak hanya menjadi acuan utama para investor di Amerika Serikat, tetapi juga berperan penting dalam membentuk ekspektasi dan keputusan investasi di pasar modal internasional, terutama di Indonesia.

➤ **Nilai Tukar Rupiah**

Nilai tukar rupiah merupakan salah satu dari beberapa variabel makroekonomi yang berperan penting dalam mencerminkan stabilitas ekonomi

nasional. Nilai tukar rupiah juga menjadi indikator kepercayaan dari para investor terhadap kondisi pasar di Indonesia. Thamrin & Masdjojo. (2025) suku bunga dan *net ekspor* adalah faktor utama yang akan mempengaruhi nilai tukar Rupiah. Suku bunga yang tinggi akan menarik aliran modal untuk masuk dan memperkuat rupiah, sedangkan defisit neraca perdagangan akan cenderung melemahkan nilai tukar rupiah [25]. Penurunan nilai tukar rupiah secara signifikan dapat memberikan dampak negatif terhadap pergerakan IHSG. Hal ini menunjukkan bahwa saat nilai Rupiah melemah, investor lebih banyak melakukan aksi jual saham karena turunya kepercayaan investor kepada pasar modal di Indonesia [26].

Boimau dkk. (2024) ketika nilai rupiah melemah akan berdampak negatif pada *stock return* perusahaan di sektor properti dan *real estate*, dikarenakan akan meningkatkan biaya impor bahan baku dan tekanan inflasi yang akan mengurangi profitabilitas perusahaan [27]. Octavian (2025) fluktuasi dari nilai

tukar USD/IDR akan berpengaruh signifikan terhadap pergerakan indeks harga saham sektoral, seperti sektor-sektor berbasis impor akan lebih sensitif terhadap perubahan kurs [28]. Hasil tersebut menjadi bukti bahwa nilai tukar rupiah tidak hanya menjadi indikator ekonomi makro, tetapi juga sebagai faktor penentu dinamika investasi dan stabilitas pasar modal di Indonesia. Kebijakan stabilitas nilai tukar rupiah harus menjadi prioritas penting bagi otoritas moneter untuk menjaga pertumbuhan ekonomi yang berkelanjutan dan menarik minat investor domestik maupun asing.

➤ **Web Scrapping**

Web scrapping adalah teknik pengambilan data terstruktur secara otomatis dari halaman web untuk tujuan mengubah konten HTML menjadi *dataset* yang dapat dianalisis. *Web scrapping* telah berkembang cepat dan mencakup beberapa metode, mulai dari parsing HTML sederhana sampai crawler berskala besar. *Web scrapping* telah berkembang pesat dan

mencakup berbagai pendekatan, di mulai dari HTML Parsing sederhana hingga *web crawler* skala besar [29]. Banyak alat dan *framework* digunakan untuk mendukung proses *web scrapping*. Mulai dari *Yfinance* dan *Requests* untuk mengekstraksi data tingkat tinggi, *Scrapy* untuk *crawling data* secara sistematis, dan *Selenium* atau *Playwright* untuk menangani konten dinamis berbasis *JavaScript* [30]. Kegunaan *web scrapping* saat ini sudah sangat luas, seperti digunakan sebagai riset pemasaran dan analisis sentimen, pemantauan harga di *e-commerce*, sampai riset ilmiah yang membutuhkan data dalam jumlah besar. Hal ini membuat *web scrapping* menjadi alat yang sangat penting dalam pengumpulan data di berbagai kegunaan [31].

➤ ***Yahoo Finance***

Yahoo Finance adalah platform penyedia data keuangan yang menyediakan banyak informasi terkait pasar modal, mulai dari harga saham, indeks, obligasi, nilai tukar, dan berbagai berita ekonomi internasional

secara *real-time*. Platform ini juga menyediakan banyak data historis harga saham yang dapat diunduh dalam format seperti *CSV* atau *excel*. *Yahoo Finance* menjadi salah satu sumber data yang paling banyak digunakan dalam kajian akademik, karena akses yang terbuka dan kemudahan dalam menyajikan data pasar saham secara global [32]. Penyediaan data yang luas menjadikan *Yahoo Finance* digunakan oleh banyak peneliti dalam menganalisis tren pasar, fluktuasi harga, serta hubungan antar variabel ekonomi dan keuangan secara luas.

Yahoo Finance tidak hanya menyediakan informasi tentang harga saham harian, tetapi juga menampilkan data fundamental dari perusahaan, seperti laporan keuangan, rasio profitabilitas, dan kapitalisasi pasar. Informasi ini sangat penting bagi peneliti sebagai dasar dalam melakukan analisis fundamental, yaitu menganalisis nilai intrinsik saham berdasarkan kondisi keuangan perusahaan. Berbagai pembahasan terbaru juga menggunakan *Yahoo Finance* sebagai sumber data utama dalam

mengembangkan model prediksi harga saham berbasis *machine learning* dan *deep learning*. *Yahoo Finance* banyak digunakan untuk mengembangkan model prediktif seperti LSTM dan GRU, karena memiliki kestabilan dan kelengkapan data [33][34]. *Yahoo Finance* berperan sangat penting sebagai penyedia data finansial yang kredibel dan menjadi fondasi utama dalam mengembangkan kajian di bidang ekonomi, investasi, maupun analisis pasar modal berbasis data.

BAB III

Gated Reccurent Unit

➤ Peramalan (*Forecasting*)

Peramalan adalah tahapan sistematis untuk memprediksi nilai di masa yang akan datang menggunakan data historis dan analisis dari pola yang sudah ada [35]. Peramalan memiliki tujuan untuk membantu dalam pengambilan keputusan dalam merencanakan suatu kebijakan, melakukan anti-sipasi perubahan harga pasar, serta mengurangi ketidakpastian di masa depan [36]. Peramalan akan melibatkan penggunaan pola dan tren dari masa lalu untuk memprediksi nilai-nilai di masa depan dengan sangat sistematis. Dalam ilmu ekonomi dan keuangan, peramalan akan berperan penting untuk memproyeksikan indikator-indikator seperti inflasi, suku bunga, harga saham, dan nilai tukar. Hal ini digunakan agar kebijakan ekonomi dan investasi dapat dilakukan secara terpola sesuai prediksi peramalan [37].

Untuk melakukan peramalan, perlu mempertimbangkan metode yang sesuai berdasarkan karakteristik data dan tujuan prediksi yang diinginkan. Secara umum, metode peramalan dibagi menjadi 2 kelompok, yaitu metode kualitatif dan kuantitatif [38]. Metode kualitatif dapat digunakan ketika data numerik dari masa lalu belum cukup atau bahkan belum ada sama sekali. Metode ini akan menggunakan pengalaman dan pendapat para ahli untuk melakukan prediksi. Sementara itu, metode kuantitatif akan menggunakan data numerik dari masa lalu yang telah tersusun sistematis untuk menghasilkan prediksi yang baik. Metode ini dapat digunakan ketika data historis cukup banyak dan memiliki pola yang dapat diprediksi.

Metode peramalan tidak hanya berdasarkan pendekatan karakteristik data, metode peramalan juga dapat dibedakan berdasarkan jangka waktu penerapan. Yulius & Yetti. (2025) metode peramalkan berdasarkan jangka waktu dibedakan menjadi 3 kategori, yaitu peramalan jangka pendek, jangka


menengah, dan jangka panjang. Peramalan jangka pendek hanya menggunakan data dengan periode maksimal satu tahun dan akan digunakan untuk memprediksi tujuan operasional seperti pengendalian produksi atau distribusi. Peramalan jangka menengah akan memiliki periode waktu antara satu sampai lima tahun, sering digunakan untuk memprediksi perencanaan kapasitas dan penentuan kebijakan manajerial. Sedangkan peramalan jangka panjang akan memiliki periode waktu lebih dari lima tahun, sering digunakan untuk mendukung perencanaan strategis dan pengambilan keputusan jangka panjang, seperti kebijakan ekonomi atau pembangunan infrastruktur nasional [39].

➤ **Data Runtun Waktu (*Time Series*)**

Data Runtun Waktu (*Time-Series*) adalah kumpulan data yang berurutan berdasarkan waktu tertentu, seperti harian, bulanan, dan tahunan [40]. Data runtun waktu dapat digunakan untuk menganalisis pola dan tren dalam periode waktu tertentu. Pada bidang

ekonomi, keuangan, cuaca, atau industri, data runtun waktu akan berperan untuk melihat pergerakan variabel seperti harga saham, nilai tukar, atau tingkat produksi. Melalui analisis deret waktu, data historis dapat digunakan untuk memprediksi nilai di masa depan menggunakan metode peramalan yang sesuai. Yusuf & Mulyani (2024) analisis data runtun waktu sangat efektif untuk memprediksi tren ekonomi, karena data runtun mampu menangkap pola musiman dan perubahan jangka panjang secara lebih sistematis [41]. Pola data runtun akan terbagi menjadi beberapa komponen utama [42]:


- a. Pola Tren (*Trend*): merupakan pola pergerakan jangka panjang dalam data, yang akan menunjukkan arah umum apakah data meningkat, menurun, atau stabil berdasarkan waktu. Tren pola akan bersifat linier atau non-linier yang akan mencerminkan perubahan struktur dalam data. Gambar 1 adalah contoh pola tren.



Gambar 1. Pola Trend

Sumber: www.geeksforgeeks.org


- b. Pola Musiman (*Seasonality*): merupakan pola pergerakan yang fluktuasi secara berkala dalam interval waktu tertentu, seperti harian, mingguan, bulanan, dan tahunan. Pola ini biasanya disebabkan oleh faktor musiman dan kalender. Faktor musiman yang mempengaruhi adalah cuaca, liburan, dan siklus produksi. Gambar 2 adalah contoh pola musiman.



Gambar 2. Pola Musiman

Sumber: www.geeksforgeeks.org


- c. Pola Siklus (*Cycle*): merupakan pola naik turun untuk jangka menengah dan jangka panjang, biasanya berhubungan dengan kondisi ekonomi. Contoh, ketika ekonomi sedang tumbuh, penjualan atau produksi pasti akan meningkat, tetapi ketika ekonomi melemah, penjualan atau produksi juga pasti akan menurun. Pola siklus berbeda dengan pola musiman, pola siklus tidak memiliki periode waktu yang tetap, karena pola siklus sangat bergantung pada perubahan ekonomi global atau nasional. Gambar 3 adalah contoh data pola siklus.



Gambar 3. Pola Siklus

Sumber: www.geeksforgeeks.org

- d. Pola Komponen Acak (*Irregular/Noise*): merupakan pola yang menggambarkan perubahan dalam data secara tiba-tiba tanpa bisa diprediksi sebelumnya. Contohnya adalah lonjakan harga akibat bencana alam, krisis ekonomi, atau peristiwa tidak terduga lain. Pola ini tidak mengikuti pola tren, musiman, atau siklus, sehingga dianggap sebagai gangguan atau variasi acak yang membuat data menjadi tidak teratur. Gambar 4 adalah contoh pola komponen acak.



Gambar 4. Pola Komponen Acak

Sumber: www.geeksforgeeks.org

➤ ***Artificial Intelligence (AI)***

Artificial Intelligence (kecerdasan buatan) adalah cabang ilmu yang lebih berfokus untuk pengembangan pembelajaran mesin yang dapat meniru kecerdasan manusia [43]. AI akan bekerja dengan cara menggunakan algoritma dan data yang akan membuat model dan dapat beradaptasi dengan situasi baru. Teknologi AI dapat diterapkan dalam berbagai sektor seperti kesehatan, pendidikan, dan

industri untuk meningkatkan efisiensi. Dengan kemampuan dalam otomatisasi dan analisis data yang kompleks, AI menjadi salah satu pendorong utama transformasi digital di era modern.

➤ ***Machine Learning (AI)***

Machine Learning adalah cabang dari kecerdasan buatan (*Artificial Intelligence*) untuk pengembangan sistem yang dapat belajar secara otomatis dari data tanpa harus diprogram secara eksplisit untuk setiap tugas tertentu [44]. *Machine learning* akan mempelajari sendiri pola atau hubungan yang tersembunyi dalam data melalui proses training dan akan menggunakan hasil training untuk membuat prediksi atau keputusan baru. Teknologi *ML* telah berkembang pesat karena kemampuannya dalam menangani data dalam jumlah besar dan kompleks. *ML* juga terus meningkatkan akurasi seiring bertambahnya data yang dipelajari. Algoritma *ML* dapat digunakan seperti mengenali wajah, memprediksi harga saham, atau merekomendasikan

produk kepada pengguna berdasarkan riwayat perilaku pengguna sebelumnya. Berikut adalah beberapa penjelasan jenis-jenis *Machine Learning* [45]:

a. *Supervised Learning*

Supervised Learning adalah jenis *machine learning* dengan menggunakan data yang sudah memiliki label atau target tertentu. Sistem yang akan dilatih sudah mengerti hasil yang benar dan belajar untuk memprediksi hubungan antara *input* dan *output*. Contoh dari jenis ini adalah peramalan cuaca, dengan *input* seperti suhu, tekanan udara, dan kecepatan angin, sedangkan *output*-nya adalah kondisi cuaca.

b. *Unsupervised Learning*

Unsupervised Learning adalah jenis *machine learning* dengan menggunakan data yang tidak memiliki label atau target tertentu. Algoritma harus menemukan struktur atau pola tersembunyi dalam data secara otomatis. Jenis ini sering digunakan

untuk segmentasi pasar, deteksi anomali, dan analisis kelompok pelanggan.

c. *Semi-Supervised Learning*

Semi-supervised learning adalah gabungan dari supervised dan *unsupervised learning*. Model ini akan dilatih menggunakan sebagian kecil data berlabel dan sebagian besar data tidak berlabel. Pendekatan ini akan membantu ketika pelabelan data membutuhkan biaya yang sangat tinggi dan waktu lama.

d. *Self-Supervised Learning*

Self-supervised learning adalah pengembangan dari *unsupervised learning*. Model ini akan secara otomatis membuat label dari sebagian datanya untuk mempelajari bagian lain. Pendekatan ini sangat berguna untuk pemrosesan bahasa alami (*Natural Language Processing*) dan visi komputer (*Computer Vision*) yang memerlukan data dalam jumlah besar.


e. *Reinforcement Learning*

Reinforcement Learning adalah jenis pengembangan program dinamis yang akan melatih algoritma menggunakan sistem penghargaan dan hukuman. Untuk menjalankan *reinforcement learning*, agen akan mengambil tindakan dalam lingkungan tertentu untuk mencapai tujuan yang telah ditentukan sebelumnya.

➤ ***Deep Learning***

Deep Learning adalah metode pembelajaran mesing yang memanfaatkan jaringan saraf tiruan dalam (*deep neural networks*). *Deep learning* akan menggunakan banyak lapisan tersembunyi untuk memproses data mentah dan mengesktrak fitur secara otomatis tanpa perlu campur tangan manusia untuk membuat aturan dengan jelas. Model *deep learning* akan bekerja dengan cara memasukkan data ke lapisan input, lalu melewati beberapa lapisan tersembunyi yang masing-masing lapisan akan melakukan tranformasi non-

linier seperti fungsi aktivasi, akhirnya akan menghasilkan *output* prediksi atau klasifikasi melalui lapisan *output*. Selama proses pelatihan, algoritma seperti *backpropagation* akan digunakan untuk menghitung kesalahan antara prediksi dan target, lalu bobot antar *neuron* akan diperbarui menggunakan *optimizer* seperti Adam atau SGD. *Optimizer* Adam atau SGD akan mengurangi kesalahan dalam iterasi-iterasi berikutnya [46]. Gambar 5 adalah alur dari arsitektur *deep learning*.



Gambar 5. Arsitektur Deep Learning

Sumber: <https://www.ibm.com/>


Secara umum, *deep learning* memiliki beberapa tipe arsitektur untuk digunakan sesuai karakteristik data dan tujuan pemrosesan. Tipe pertama adalah *Convolutional Neural Network (CNN)* yang digunakan untuk menganalisis data spasial, seperti gambar atau video dengan memanfaatkan lapisan konvolusi untuk mengenali fitur visual secara bertingkat. Selanjutnya adalah *Recurrent Neural Network (RNN)* yang digunakan untuk mengolah data runtun waktu (*time series*) atau data yang memiliki urutan logis seperti teks, suara, dan data finansial. *RNN* memiliki koneksi umpan balik yang memungkinkan informasi dari langkah sebelumnya memberi pengaruh pada proses langkah selanjutnya, sehingga sangat cocok untuk melakukan prediksi berbasis waktu, seperti peramalan harga saham, analisis cuaca, atau prediksi tren ekonomi. Terakhir adalah tipe *Autoencoder* yang digunakan untuk mereduksi dimensi dan representasi fitur, serta *Generative Adversarial Network (GAN)* yang mampu menghasilkan data baru berdasarkan pola dari data pelatihan.

➤ **Recurrent Neural Network (RNN)**

Recurrent Neural Network (RNN) adalah salah satu arsitektur dari *deep learning* yang dirancang untuk mengolah data berurutan (*sequential data*) atau data *time series*. RNN memiliki arsitektur berbeda dengan jaringan saraf tiruan biasa (*feedforward neural network*). Jaringan saraf tiruan biasa hanya memproses data satu arah, tetapi RNN memiliki koneksi umpan balik (*feedback connections*) yang akan mengambil informasi sebelumnya untuk disimpan dan digunakan dalam memproses data berikutnya. Kemampuan RNN sangat efektif untuk memahami data hubungan antar waktu, sehingga sangat relevan untuk melakukan prediksi data runtun waktu[47].

Recurrent Neural Network (RNN) memiliki cara kerja dengan berfokus pada konsep *hidden state*, yaitu representasi internal yang akan diperbarui secara berurutan setiap kali data baru masuk. Setiap langkah waktu (*time step*) dari RNN akan menerima masukan dan informasi baru dari langkah sebelumnya untuk menghasilkan *output* serta memperbarui memori.

Namun, RNN konvensional masih menghadapi masalah *vanishing gradient* ketika melatih data dengan urutan panjang, informasi awal akan sulit dipertahankan karena gradien dapat menurun seiring bertambahnya waktu. Untuk mengatasi masalah tersebut, dikembangkan varian RNN seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) yang dilengkapi mekanisme gerbang (*gating mechanism*) untuk mengontrol aliran informasi dan tetap menjaga memori jangka panjang.



Gambar 6. Struktur *Recurrent Neural Network* (RNN)

Sumber: <https://www.ibm.com/>

Arsitektur RNN terdiri dari tiga komponen utama, yaitu lapisan input, lapisan tersembunyi (*hidden layer*) yang memiliki koneksi berulang untuk menyimpan memori konteks, dan lapisan *output* untuk menghasilkan prediksi. Proses pelatihan RNN menggunakan algoritma *backpropagation through time* (BPTT) yang akan menyesuaikan bobot jaringan berdasarkan kesalahan prediksi pada setiap langkah waktu. Dari struktur dan mekanisme ini, RNN mampu mengingat informasi jangka pendek hingga menengah. RNN sangat cocok untuk digunakan pada sistem yang bergantung pada urutan data seperti data ekonomi.


➤ ***Gated Recurrent Unit (GRU)***

Gated Recurrent Unit (GRU) adalah salah satu jenis jaringan saraf berulang (Recurrent Neural Network) yang memiliki struktur koneksi antar *neuron* dengan siklus umpan balik (feedback loop). GRU dibuat sebagai solusi untuk permasalahan klasik pada RNN konvensional. Permasalahan RNN konvensional

adalah *vanishing gradient* dan *exploding gradient* yang sering terjadi ketika jaringan belajar dari urutan data yang panjang (*long-term dependencies*). Permasalahan ini menyebabkan model akan kesulitan dalam mempertahankan informasi dari waktu sebelumnya, sehingga akan membuat performa model menurun pada data sekuensial jangka panjang. Melalui mekanisme gerbang (*gating mechanism*), algoritma GRU mampu mempertahankan dan memperbarui informasi penting pada setiap langkah waktu, sehingga membuat model akan lebih stabil dan efisien dalam mempelajari hubungan temporal dibandingkan RNN biasa. GRU memiliki struktur yang lebih sederhana dibandingkan *Long Short-Term Memory* (LSTM), karena hanya menggunakan dua gerbang utama. GRU akan lebih ringan secara komputasi dan cepat dalam proses pelatihan.

Secara arsitektual, GRU masuk ke dalam kategori *gated RNNs* yang terdiri dari tiga komponen utama, yaitu lapisan input, lapisan tersembunyi (*hidden layer*), dan lapisan *output*. Lapisan *input* akan

berfungsi sebagai penerimaan data berurutan berdasarkan urutan waktu (*chronological order*). Lapisan tersembunyi akan memiliki sel memori (*memory cells*) yang menjadi pusat dari proses pembelajaran GRU. Dalam lapisan tersembunyi terdapat dua gerbang utama, yaitu *reset gate* (r_t) dan *update gate* (u_t) yang akan bertugas untuk mengatur seberapa besar informasi dari langkah sebelumnya dipertahankan atau diabaikan. Kedua gerbang ini akan bekerja sama agar jaringan dapat memproses informasi baru tanpa kehilangan konteks historis dari data sebelumnya.



Gambar 7. Arsitektur *Gated Recurrent Unit*

Untuk memahami cara kerja GRU secara lebih sistematis, setiap mekanisme gerbang akan dierpresentasikan melalui beberapa rumus berikut:

A. *Reset Gate* (r_t)

Reset gate akan berperan dalam mengontrol sejauh mana informasi dari *hidden state* sebelumnya (h_{t-1}) mempengaruhi *input* saat ini (x_t). Jika nilai (r_t) kecil, maka sebagian besar informasi waktu sebelumnya akan dihapus, sehingga akan memungkinkan jaringan untuk lebih fokus pada informasi baru. Rumus matematis *reset gate* sebagai berikut:

$$(r_t) = \sigma (W_r x_t + U_r h_{t-1} + b_r)$$

Penjelasan rumus *reset gate*:

- a. x_t adalah *input* pada waktu ke- t .
- b. h_{t-1} adalah *hidden state* dari waktu sebelumnya.
- c. W_r dan U_r masing-masing adalah bobot yang menghubungkan *input* dan *hidden state* sebelumnya.
- d. b_r adalah nilai bias.

- e. σ adalah fungsi aktivasi *sigmoid* yang mengubah nilai linear menjadi rentang antara 0 hingga 1.
- f. Nilai r_t yang mendekati 0 membuat jaringan akan melupakan informasi lama, sedangkan nilai mendekati 1 memungkinkan pengaruh memori lama tetap lebih kuat.

B. *Update Gate* (z_t)

Update gate akan berfungsi sebagai penentu keseimbangan antara informasi baru dan informasi lama yang akan dipertahankan dalam memori. Ketika nilai (z_t) mendekati 1, maka sebagian besar memori lama akan dipertahankan. Tetapi, ketika nilai (z_t) mendekati 0, maka informasi baru akan menjadi lebih dominan. Penjelasan rumus *update gate*:

$$(z_t) = \sigma (W_z x_t + U_z h_{t-1} + b_z)$$

Penjelasan rumus *update gate*:

- a. W_z dan U_z adalah bobot yang terhubung dengan *input* dan *hidden state* sebelumnya.
- b. b_z adalah nilai bias.

- c. Nilai z_t inilah yang menentukan keseimbangan antara memori lama dan informasi baru pada langkah waktu ke- t .

C. *Candidate Hidden State* ($\sim h_t$)

Setelah kedua nilai gerbang dihitung, GRU akan membentuk *candidate hidden state* ($\sim h_t$) yang akan mempresentasikan informasi baru hasil dari kombinasi antara *input* saat ini dan *hidden state* sebelumnya yang telah disesuaikan dengan *reset gate*. Rumus *candidate hidden state* sebagai berikut:

$$\sim h_t = \tanh(W_h x_t + U_h(r_t \odot h_{t-1}) + b_h)$$

Penjelasan rumus *candidate hidden state*:

- a. Simbol $\odot$ menunjukkan operasi perkalian elemen (element-wise) antara r_t dan h_{t-1} .
- b. W_h dan U_h masing-masing adalah bobot yang menghubungkan *input* dan *hidden state*.
- c. b_h adalah nilai bias.
- d. fungsi *tanh* digunakan untuk membatasi nilai hasilnya antara -1 hingga 1.

Reset gate berperan penting di sini, karena akan menentukan sejauh mana memori lama ikut membentuk kandidat memori baru.

D. *Final Hidden State* (h_t)

Final hidden state akan dihitung sebagai gabungan dari memori lama dan memori baru menggunakan mekanisme *update gate*. Rumus *final hidden state* sebagai berikut:

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$$

Penjelasan rumus *final hidden state*:

- komponen $(1 - z_t)$ akan mengatur berapa banyak memori lama yang dipertahankan.
- z_t akan mengontrol seberapa besar kontribusi memori baru.

Rumus ini akan menggambarkan bagaimana GRU bekerja secara dinamis untuk menyesuaikan perbandingan antara informasi lama dan baru pada setiap langkah waktu. Dengan mekanisme ini, GRU akan mampu mempertahankan informasi jangka panjang tanpa kehilangan konteks temporal, dan

menjadikan model menjadi sangat efektif dalam menangani data berurutan seperti saham.

E. *Output Layer* (y)

Setelah seluruh proses pada lapisan tersembunyi selesai, hasil akhir diteruskan ke lapisan *output* (*output layer*). Lapisan ini akan berfungsi untuk mengubah *hidden state* terakhir menjadi bentuk *output* yang sesuai dengan tujuan prediksi. Rumus *output layer* sebagai berikut:

$$y = W_o \cdot h_t + b_o$$

Penjelasan rumus *output layer*:

- W_o adalah bobot pada lapisan *output*.
- h_t adalah *final hidden state*.
- b_o adalah bias pada lapisan *output*.

Dalam rumus diatas, W_o adalah bobot pada lapisan *output*, h_t adalah *final hidden state*, dan b_o adalah nilai bias. Nilai y kemudian akan diproses lebih lanjut menggunakan fungsi aktivasi. Lapisan *output* ini akan memastikan bahwa hasil dari pembelajaran model GRU dapat diterjemahkan ke

dalam bentuk *output* yang relevan sesuai konteks permasalahan, seperti prediksi harga saham.

➤ ***Hyperparameter* GRU**

Hyperparameter adalah parameter konfigurasi eksternal yang akan digunakan untuk menentukan proses pelatihan dan memberikan pengaruh besar terhadap arsitektur serta performa model. *Hyperparameter* memiliki sifat tetap selama proses pelatihan dan sesuai dengan yang telah ditentukan dari awal [48]. Pada model GRU, *hyperparameter* akan berperan penting sebagai penentuan efisiensi dan akurasi model. Beberapa *hyperparameter* kunci GRU meliputi [49]:

- a. Jumlah unit *neuron*: akan mempengaruhi kapasitas representasi data oleh model.
- b. Jumlah lapisan GRU: akan menentukan kedalaman jaringan dan kemampuan untuk menangkap pola yang kompleks.
- c. *Learning rate*: akan mengatur laju pembaruan bobot selama pelatihan.

- d. *Drouput rate*: akan mencegah terjadinya *overfitting* dengan cara menonaktifkan sebagian *neuron* sementara.
- e. *Batch size*: adalah jumlah data yang diproses dalam satu iterasi pelatihan.
- f. *Optimizer*: adalah algoritma yang digunakan untuk meminimalkan fungsi loss.

Pemilihan dan konfigurasi *hyperparameter* yang optimal sangat penting untuk meningkatkan performa model dan menghindari *underfitting* atau *overfitting*. *Hyperparameter* yang tepat dapat membantu model untuk mencapai keseimbangan sehingga tidak mengalami *underfitting* maupun *overfitting*. Pengaturan *hyperparameter* yang optimal juga akan berkontribusi pada peningkatan akurasi serta konsistensi hasil prediksi. Sehingga model akan bekerja lebih stabil ketika mempelajari pola dan memprediksi data di masa depan.

➤ Fungsi Aktivasi


Fungsi aktivasi adalah komponen penting dalam jaringan saraf tiruan untuk mengubah keluaran *neuron* menjadi bentuk non-linier. Penerapan dari fungsi aktivasi akan memungkinkan model untuk mempelajari dan menangkap hubungan non-linier antara *input* dan *output*. Tanpa menggunakan fungsi aktivasi non linier, jaringan saraf yang memiliki banyak lapisan hanya akan menjadi kombinasi linier dari input. Sehingga, model tidak akan mampu memetakan pola atau data yang kompleks secara efektif [50]. Berikut ini adalah beberapa kategori fungsi aktivasi yang sering digunakan secara umum:

a. Fungsi *Sigmoid*

Sigmoid adalah fungsi aktivasi non-linier klasik yang banyak digunakan pada awal perkembangan jaringan saraf. Fungsi *sigmoid* akan mengubah nilai *input* dan output dalam rentang 0-1, sehingga akan membantu untuk tugas klasifikasi biner. Tetapi, fungsi *sigmoid* memiliki bagian kurva yang mendatar di kedua ujung (saturasi), sehingga

gradien yang dimiliki akan menjadi sangat kecil untuk *input* data besar atau kecil. Hal ini akan menyebabkan masalah vanishing gradient dan akan membuat jaringan sulit untuk mempelajari model. Rumus fungsi *sigmoid* adalah sebagai berikut:

$$f_{sign}(x) = \frac{1}{1 + e^{-x}}$$




Gambar 8. Fungsi Sigmoid

b. Fungsi *Tanh*

Fungsi *Tanh* adalah fungsi seperti *sigmoid* namun memiliki *output* dengan rentan -1-1. Fungsi ini memiliki sifat zero-centred yang berarti nilai *output* dapat bernilai negatif atau positif dengan rata-rata mendekati nol. Fungsi *Tanh* memiliki keuntungan dalam optimasi dari pada *sigmoid* yang memiliki *output* dalam rentang 0-1. Namun, *Tanh* juga masih memiliki keterbatasan seperti *sigmoid*, yaitu saturasi pada nilai *input* yang sangat besar atau kecil. sehingga akan membuat penyebab terjadinya vanishing gradient. Rumus fungsi *Tanh* adalah sebagai berikut:

$$f_{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$




Gambar 9. Fungsi *Tanh*

c. Fungsi *ReLU* (*Rectified Linear Unit*)

Fungsi *ReLU* adalah salah satu fungsi aktivasi modern dan banyak digunakan karena memiliki kesederhanaan dan efektivitas. Fungsi ini akan menghasilkan *output* positif jika inputnya positif, tapi akan menghasilkan *output* nol jika inputnya negatif. Penggunaan *ReLU* telah menjadi standar untuk arsitektur jaringan saraf, karena mampu

mengatasi permasalahan vanishing gradient yang sering terjadi pada fungsi aktivasi klasik. Namun, *ReLU* juga masih memiliki kelemahan, yaitu memiliki potensi munculnya *dead neurons*. *Dead neurons* adalah kondisi ketika *neuron* tidak lagi aktif, karena terus menerima *input* bernilai negatif, sehingga tidak akan berkontribusi dalam proses pembelajaran. Rumus fungsi *ReLU* adalah sebagai berikut:

$$f_{relu}(x) = \max(0, x)$$



Gambar 10. Fungsi ReLU

➤ Pendefinisian Fitur dan Target

Pendefinisian fitur dan target adalah tahapan penting pada saat proses pemodelan prediktif. Fitur adalah variabel independen yang akan menjadi *input* ke model untuk mempelajari pola historis dari data. Target adalah variabel dependen yang akan menjadi objek prediksi utama pada data. Anisa dkk. (2024), mereka melakukan pemodelan linier regresi berganda untuk harga saham PT Bank Rakyat Indonesia. Mereka menetapkan kolom harga pembukaan, harga tertinggi, harga terendah, dan *net buy/sell* asing sebagai fitur, sedangkan kolom harga penutupan dijadikan target utama untuk di prediksi [52].

Tabel 1. *Sample Data Fitur dan Target*

Data Target	Data Fitur
Harga penutupan	Harga pembukaan
	Harga tertinggi
	Harga terendah
	<i>Net buy/sell</i> asing

➤ **Normalisasi**

Normalisasi adalah tahapan yang sangat penting pada saat pra-pemrosesan data. Tahapan normalisasi memiliki tujuan untuk menyesuaikan skala fitur dari data supaya memiliki rentan nilai yang seragam tanpa mengubah distribusi relatif. Pada data runtun (*time series*), seperti data harga saham atau nilai tukar mata uang, normalisasi akan di gunakan untuk menstabilkan perbedaan skala antar variabel yang berasal dari sumber ekonomi berbeda. Hal ini sangat penting agar model, seperti RNN atau GRU dapat mempelajari pola temporal tanpa bias akibat perbedaan satuan atau magnitudo nilai.

Kim dkk. (2025), penggunaan teknik *Min-Max-Scaling* dengan rentan 0-1 telah terbukti untuk meningkatkan konvergensi dari model GRU dan LSTM dalam melakukan peramalan harga saham. Proses ini akan mengubah setiap nilai data menjadi proposional terhadap nilai minimum dan maksimum pada fitur tersebut. Hal ini akan menyebabkan model dapat mempercepat melakukan penyesuaian bobot selama pelatihan [53]. Rumus dasar dari metode *MinMaxScaler* adalah sebagai berikut:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

X adalah nilai asli, X_{min} adalah nilai minimum dari data, dan X_{max} adalah nilai maksimum dari data. Hasil transformasi ini akan menghasilkan nilai X' yang berbeda pada rentan 0 hingga 1.

➤ Denormalisasi

Denormalisasi adalah tahapan kebalikan dari normalisasi. Denormalisasi akan mengembalikan nilai hasil prediksi ke skala data yang asli. Proses ini sangat penting karena model *deep learning* seperti LSTM dan GRU memerlukan data yang memiliki skala seragam agar proses pembelajaran tidak bias terhadap fitur dengan rentang nilai yang besar. Untuk menyeragamkan skala data, dilakukan proses normalisasi yang akan merubah data menjadi skala 0-1. Ketika model telah melakukan pembelajaran dan mendapatkan hasil prediksi, dilakukan proses denormalisasi untuk mengembalikan nilai data ke satuan aslinya. Proses ini dilakukan agar hasil prediksi dapat dibandingkan langsung dengan data aktual [54]. Rumus denormalisasi sebagai berikut:

$$Y = X'(X_{max} - X_{min}) + X_{min}$$

X' adalah nilai yang telah dinormalisasi, X_{min} adalah nilai minimum dari data, dan X_{max} adalah nilai maksimum dari data. Hasil denormalisasi ini akan menghasilkan nilai Y yang akan mengembalikan nilai ke skala asli data.

➤ Evaluasi Metrik

Metrik evaluasi pada konteks peramalan dan pemodelan *time series* akan digunakan dalam mengukur seberapa baik model mampu mempresentasikan dan memprediksi data aktual. Pemilihan metrik evaluasi yang tepat sangat penting, karena akan menentukan cara kita dalam menilai performa dan keakuratan model, serta membantu dalam proses penyesuaian *hyperparameter* dan perbandingan antar model. Faroutan & Lahmiri (2024), penggunaan metrik evaluasi seperti MSE (*Mean Squared Error*), MAPE (*Mean Absolute Percentage Error*), dan RMSE (*Root Mean Square Error*) terbukti sangat efektif dalam menilai kinerja

model prediksi berbasis *deep learning* pada data finansial yang bersifat dinamis.

MSE

Mean Squared Error (MSE) adalah salah satu metrik evaluasi yang paling umum digunakan untuk mengukur tingkat akurasi model prediksi, khususnya pada konteks peramalan harga saham atau komoditas finansial. MSE akan menghitung rata-rata dari kuadrat absolut antara nilai aktual dan nilai prediksi, sehingga akan memberikan penalti yang lebih besar terhadap kesalahan model. Dengan ini, MSE akan memberikan gambaran seberapa jauh prediksi model menyimpang kuadrat dari nilai sebenarnya dalam satuan yang sama dengan data aslinya. Rumus MSE adalah sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i|^2$$

n adalah jumlah total data, y_i adalah nilai aktual, dan $\hat{y}_i$ adalah nilai prediksi. Nilai MSE yang lebih kecil akan menunjukkan bahwa model memiliki performa yang lebih baik. Model menjadi lebih baik karena kesalahan rata-rata kuadrat antara nilai prediksi dan aktual lebih kecil. Karena MSE menggunakan kuadrat selisih, satuannya akan menjadi berbeda dengan data aslinya, sehingga metrik ini lebih sensitif terhadap outlier dibandingkan metrik seperti MAE.

RMSE

Root Mean Square Error (RMSE) juga salah satu metrik evaluasi yang paling sering digunakan dalam model peramalan. RMSE akan mengukur akar rata-rata kuadrat selisih antara nilai aktual dan nilai prediksinya. RMSE akan memberikan bobot lebih besar terhadap kesalahan yang besar (large errors). Dengan ini, RMSE sangat berguna untuk menilai sejauh mana hasil prediksi model akan menyimpang dari nilai sebenarnya, terutama ketika akurasi tinggi

sangat dibutuhkan pada konteks keuangan. Rumus RMSE adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2}$$

RMSE akan memiliki nilai satuan yang sama dengan data aktualnya, sehingga lebih mudah untuk diinterpretasikan dalam konteks nyata. Nilai RMSE yang lebih kecil akan menunjukkan bahwa prediksi model semakin akurat. Hal ini dikarenakan RMSE lebih sensitif terhadap kesalahan besar. Metrik RMSE sangat cocok digunakan ketika kesalahan besar akan dianggap lebih kritis, seperti prediksi harga saham, di mana deviasi yang besar akan berdampak signifikan pada keputusan investasi.

MAPE

Mean Absolute Percentage Error (MAPE) adalah metrik evaluasi yang akan digunakan untuk mengukur rata-rata kesalahan absolut dalam bentuk persentase terhadap nilai aktual. MAPE sangat populer untuk menganalisis peramalan, karena mampu

menunjukkan tingkat kesalahan model dalam skala yang mudah dipahami, yaitu persen (%). Dengan ini, MAPE tidak hanya akan menunjukkan besar kecilnya kesalahan, tetapi membandingkan seberapa signifikan kesalahan prediksi dengan nilai aktualnya. Rumus MAPE adalah sebagai berikut:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{x_i} \right|$$

MAPE akan memberikan interpretasi yang mudah, misalnya nilai MAPE sebesar 5%, berarti rata-rata kesalahan prediksi adalah 5% dari nilai aktual. Hal ini sangat penting untuk konteks ekonomi dan keuangan. Para investor atau analisis saham dapat memahami seberapa akurat model dalam memprediksi pergerakan harga saham. Namun, MAPE memiliki kelemahan ketika nilai aktualnya mendekati nol, karena MAPE akan menghasilkan nilai kesalahan yang tidak stabil atau sangat besar.

BAB IV

Contoh Aplikasi Model GRU

Data diperoleh dari proses *scrapping* menggunakan library python *Yfinance* di website *Yahoo Finance*. Library *Yfinance* akan melakukan ekstraksi data secara otomatis dari halaman website *Yahoo Finance* untuk mendapatkan data saham yang diinginkan. Data harga saham yang akan diambil adalah data harian yang memiliki kolom harga penutupan yang sudah disesuaikan (*Adj close*), harga penutupan (*close*), harga tertinggi (*high*), harga terendah (*low*), harga pembukaan (*open*), dan volume perdagangan. Data dari masing-masing variabel akan disimpan ke format *csv*.

Mencari data untuk: ^JKSE

```
Info DataFrame (IHSG):
<class 'pandas.core.frame.DataFrame'>
DatetimeIndex: 4125 entries, 2008-01-02 to 2024-12-30
Data columns (total 6 columns):
#   Column                Non-Null Count  Dtype
---  -
0   (Adj Close, ^JKSE)    4125 non-null   float64
1   (Close, ^JKSE)        4125 non-null   float64
2   (High, ^JKSE)         4125 non-null   float64
3   (Low, ^JKSE)          4125 non-null   float64
4   (Open, ^JKSE)         4125 non-null   float64
5   (Volume, ^JKSE)       4125 non-null   int64
dtypes: float64(5), int64(1)
memory usage: 225.6 KB
```

5 Data Pertama (IHSG):

Price Ticker	Adj Close ^JKSE	Close ^JKSE	High ^JKSE	Low ^JKSE	Open ^JKSE	Volume ^JKSE
Date						
2008-01-02	2731.401	2731.507	2740.319	2709.162	2739.586	11523000
2008-01-03	2714.959	2715.065	2717.833	2697.651	2706.542	17181800
2008-01-04	2765.082	2765.190	2769.429	2717.096	2717.096	29196600
2008-01-07	2776.302	2776.410	2776.782	2732.433	2732.433	35241700
2008-01-08	2785.517	2785.625	2800.296	2771.801	2783.607	41806000

5 Data Terakhir (IHSG):

Price Ticker	Adj Close ^JKSE	Close ^JKSE	High ^JKSE	Low ^JKSE	Open ^JKSE	Volume ^JKSE
Date						
2024-12-20	6983.865	6983.865	7032.401	6931.581	6980.175	145749700
2024-12-23	7096.445	7096.445	7096.445	7035.727	7037.530	138664700
2024-12-24	7065.746	7065.746	7120.576	7063.755	7115.637	110632900
2024-12-27	7036.571	7036.571	7100.270	7024.715	7073.375	144277600
2024-12-30	7079.905	7079.905	7079.905	6993.072	7026.777	159672400

Gambar 11. Hasil *Scrapping* Data Variabel IHSG

➤ **Pra-Pemrosesan Data**

Pra-pemrosesan data adalah tahapan awal yang memiliki tujuan untuk menyiapkan data supaya siap digunakan pada proses pelatihan model GRU. Tahapan ini akan melakukan penggabungan data dari semua variabel saham hasil *scrapping* berdasarkan tanggal yang sama. Proses selanjutnya adalah melakukan analisis korelasi dari masing-masing variabel untuk melihat hubungan dan pengaruh dari setiap fitur terhadap target prediksi. Selanjutnya adalah mendefinisikan fitur dan target secara jelas agar model bisa mempelajari pola secara relevan. Tahapan terakhir adalah melakukan normalisasi pada data agar skala antar variabel bisa sama sehingga proses pelatihan menjadi lebih stabil, cepat, dan mendapatkan hasil prediksi yang lebih akurat.

➤ Penggabungan Data

Penggabungan data adalah salah satu tahapan pra-pemrosesan data yang memiliki tujuan untuk menyatukan data dari semua variabel saham ke dalam satu *dataset* berdasarkan data kolom yang terdapat tanggal sama. Penggabungan berdasarkan filter tanggal dilakukan karena setiap variabel IHSG, Indeks DJIA, dan nilai tukar IDR/USD memiliki hari libur perdagangan yang berbeda sehingga tidak semua memiliki data di tanggal yang sama. Tanpa filter tanggal, *dataset* yang akan digunakan akan banyak memiliki nilai kosong (*missing values*) sehingga akan mengganggu proses pelatihan model. Oleh karena itu, data harus difilter dahulu berdasarkan tanggal yang sama baru digabungkan hanya berdasarkan data yang memiliki data di semua variabel. Gambar 12 adalah *dataframe* lima baris pertama dan terakhir dari proses penggabungan data.

Data Teratas:			
	IHSG	DJI	IDR/USD
Date			
2008-01-02	2731.507	13043.96	9390.8
2008-01-03	2715.065	13056.72	9417.1
2008-01-04	2765.190	12800.18	9441.8
2008-01-07	2776.410	12827.49	9439.5
2008-01-08	2785.625	12589.07	9424.7
Data Terbawah:			
	IHSG	DJI	IDR/USD
Date			
2024-12-20	6983.865	42840.262	15981.3
2024-12-23	7096.445	42906.949	16159.3
2024-12-24	7065.746	43297.031	16217.6
2024-12-27	7036.571	42992.211	16189.0
2024-12-30	7079.905	42573.730	16178.0

Gambar 12. Data Hasil Penggabungan

➤ Pendefinisian Fitur dan Target

Pendefinisian fitur dan target adalah tahapan untuk memilih variabel apa saja yang akan dijadikan menjadi fitur dan target dari model. Variabel lain seperti indeks DJIA dan nilai tukar Rupiah terhadap Dolar Amerika Serikat akan dijadikan fitur pendamping untuk model bisa mempelajari pergerakan harga

IHSG. Pemilihan fitur dan target yang tepat bisa mempengaruhi kemampuan model dalam menangkap pola hubungan antar variabel dengan lebih optimal.

➤ Normalisasi

Normalisasi adalah tahapan untuk menyamakan skala nilai data antar variabel agar memiliki rentang yang seragam. Tahapan ini sangat penting untuk pembuatan model deep learning seperti GRU, karena jika data memiliki perbedaan skala yang cukup besar akan mengakibatkan proses pelatihan menjadi tidak stabil dan memperlambat proses konvergensi model. Proses normalisasi data akan membuat model bisa mempelajari model lebih efektif dan akan mendapatkan hasil prediksi yang lebih akurat. Gambar 13 adalah hasil proses normalisasi data menggunakan *MinMaxScaler*.

```
Data berhasil dinormalisasi.  
Bentuk dataset setelah digabung: (3991, 2)  
  
Data setelah normalisasi:  
[[0.23846291 0.16787057]  
 [0.23604282 0.16820269]  
 [0.24342065 0.16152536]  
 [0.2450721  0.16223621]  
 [0.24642846 0.15603053]]
```

Gambar 13. Hasil Normalisasi Data

➤ Struktur Data

Struktur data adalah tahapan yang memiliki tujuan untuk merubah *dataset* sesuai input yang dibutuhkan oleh model GRU. GRU akan bekerja pada data sekuensial sehingga data harus diubah menjadi bentuk tiga dimensi. Data akan diubah menjadi jumlah *sample* (*samples*), panjang urutan waktu (*timesteps*), dan jumlah fitur (*features*). Penyusunan struktur data ini akan memungkinkan untuk model bisa mempelajari pola temporal berdasarkan informasi historis yang dipelajarinya menggunakan data

beberapa periode sebelumnya. Penyusunan struktur data pada tahapan ini menggunakan pendekatan *sliding window* yang digunakan untuk membentuk urutan data *time series* untuk mempresentasikan hubungan antar waktu secara berkelanjutan.

➤ **Perancangan Model GRU**

Model akan dirancang menggunakan arsitektur GRU bertingkat (*stacked GRU*) supaya model mampu untuk menangkap hubungan jangka pendek dan panjang secara lebih optimal. Parameter model seperti jumlah unit GRU, *dropout rate*, *learning rate*, jumlah *epoch* dan *batch_size* akan ditentukan sesuai nilai skenario pengujian yang telah dirancang di tahapan sebelumnya. Perancangan model ini memiliki harapan untuk mendapatkan hasil model yang stabil, efisien secara komputasi dan memiliki kemampuan memprediksi harga IHSG yang baik.

Model: "sequential"		
Layer (type)	Output Shape	Param #
gru (GRU)	(None, 60, 32)	3,456
dropout (Dropout)	(None, 60, 32)	0
gru_1 (GRU)	(None, 64)	18,816
dropout_1 (Dropout)	(None, 64)	0
dense (Dense)	(None, 1)	65
Total params: 22,337 (87.25 KB)		
Trainable params: 22,337 (87.25 KB)		
Non-trainable params: 0 (0.00 B)		

Gambar 14. Contoh *Sample Model Summary*

Gambar 14 menjelaskan *sample* salah satu model *summary* yang menunjukkan arsitektur dari model GRU bertingkat yang terdiri dari dua lapisan GRU, dua lapisan dropout, dan satu lapisan output. Lapisan GRU pertama memiliki 32 unit dengan output yang berbentuk sekuens dengan nilai (None, 60, 32) sehingga seluruh informasi temporal akan diteruskan ke informasi sebelumnya. Lapisan kedua GRU memiliki 64 unit dan mendapatkan hasil output akhir dengan nilai (None, 64) sebagai representasi dari fitur.

Lapisan *dropout* akan disipkan ke setiap lapisan GRU untuk mengurangi risiko *overfitting* dari model tambah menambah parameter lagi. Lapisan dense dengan nilai satu neuron akan digunakan sebagai output akhir untuk menghasilkan nilai prediksi IHSG. Secara keseluruhan model memiliki 22.337 parameter yang menunjukkan kompleksitas model namun tetap efisien untuk prediksi data *time series* seperti IHSG.

```


Epoch 1/30
98/98 ————— 10s 54ms/step - loss: 0.0065 - val_loss: 2.9976e-04
Epoch 2/30
98/98 ————— 4s 44ms/step - loss: 0.0012 - val_loss: 4.1348e-04
Epoch 3/30
98/98 ————— 4s 45ms/step - loss: 9.5194e-04 - val_loss: 2.3053e-04
Epoch 4/30
98/98 ————— 4s 44ms/step - loss: 8.5091e-04 - val_loss: 0.0024
Epoch 5/30
98/98 ————— 4s 44ms/step - loss: 6.6511e-04 - val_loss: 2.1380e-04
Epoch 6/30
98/98 ————— 4s 44ms/step - loss: 6.1457e-04 - val_loss: 4.6552e-04
Epoch 7/30
98/98 ————— 4s 45ms/step - loss: 6.9859e-04 - val_loss: 4.4176e-04
Epoch 8/30
98/98 ————— 4s 44ms/step - loss: 5.0881e-04 - val_loss: 1.0250e-04
Epoch 9/30
98/98 ————— 5s 47ms/step - loss: 5.3648e-04 - val_loss: 1.9846e-04
Epoch 10/30
98/98 ————— 5s 46ms/step - loss: 4.2621e-04 - val_loss: 1.8961e-04
Epoch 11/30
98/98 ————— 5s 46ms/step - loss: 4.1510e-04 - val_loss: 1.0274e-04
Epoch 12/30
98/98 ————— 5s 48ms/step - loss: 4.0961e-04 - val_loss: 3.0024e-04
Epoch 13/30
98/98 ————— 5s 47ms/step - loss: 3.6441e-04 - val_loss: 3.6994e-04
Epoch 13: early stopping
Restoring model weights from the end of the best epoch: 8.
Waktu pelatihan: 64.30 detik

```

**Gambar 15. Contoh *Sample* Pelatihan Model
Menggunakan *Early Stopping***

Gambar 15 menampilkan hasil pelatihan model yang menunjukkan nilai loss dan validation loss mengalami penurunan pada beberapa *epoch* awal untuk menandakan bahwa model mampu mempelajari pola data dengan baik. Performa terbaik dari model dicapai pada *epoch* ke-7 yang memiliki nilai validation loss terendah sekitar 1.0250e-04. Setelah

epoch 8 nilai validation loss cenderung berfluktuasi dan tidak mendapatkan perbaikan nilai yang signifikan. Oleh karena itu mekanisme *Early Stopping* akan bekerja untuk menghentikan proses pelatihan pada *epoch* ke-13. Bobot model akan dikembalikan ke kondisi terbaik pada *epoch* ke-8 untuk mencegah terjadinya kondisi overfitting. Waktu pelatihan mendapatkan total waktu 64,30 detik yang menunjukkan bahwa arsitektur GRU yang digunakan telah cukup efisien dalam proses komputasi. Gambar 16 menampilkan visualisasi proses pelatihan model.



Gambar 16. Contoh Visualisasi Proses Pelatihan Model

➤ Denormalisasi


Denormalisasi adalah tahapan untuk mengembalikan nilai hasil prediksi dari model dan data aktual ke skala aslinya setelah sebelumnya dilakukan proses normalisasi. Tahapan ini sangat penting dilakukan supaya nilai prediksi harga IHSG yang dihasilkan oleh model GRU dapat diinterpretasikan secara nyata dan dapat dibandingkan dengan data aktual dalam nilai satuan aslinya. Tanpa proses denormalisasi, hasil

nilai prediksi akan tetap berada pada rentang 0 sampai 1 sehingga mengurangi performa analisis model. Hal ini menyebabkan denormalisasi sebagai tahapan terakhir sebelum model dievaluasi dan divisualisasikan hasil prediksinya.


➤ Evaluasi Model

Evaluasi model adalah tahapan terakhir untuk mengukur kinerja dari model GRU dalam memprediksi nilai harga IHSG dengan cara membandingkan hasil prediksi terhadap data aktual pada data testing. Tahapan ini memiliki tujuan untuk mengetahui tingkat kesalahan prediksi serta melihat sejauh mana model mampu untuk mempresentasikan pola pergerakan dari data aslinya. Evaluasi model ini menggunakan metrik umum yang digunakan pada prediksi model *time series* seperti *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Penggunaan evaluasi model menggunakan lebih dari satu metrik memiliki tujuan untuk memberikan gambaran dari

performa model secara lebih komprehensif. Gambar 17 menampilkan nilai evaluasi model dalam memprediksi harga IHSG. Gambar 18 menampilkan perbandingan grafik nilai aktual dan prediksi harga IHSG menggunakan data testing.



Gambar 17. ContohNilai Evaluasi Model



Gambar 18. Contoh Perbandingan Grafik Nilai Aktual dan Prediksi

BAB V

Performa dan Konfigurasi Optimal Model

Berdasarkan Tabel 2, terdapat hasil evaluasi seluruh skenario yang menunjukkan bahwa variasi fitur, rasio pembagian data, dan kompleksitas arsitektur model akan memberikan pengaruh yang cukup signifikan terhadap performa model dalam memprediksi nilai IHSG. Secara umum, variabel indeks DJIA yang digunakan fitur menghasilkan nilai kesalahan yang lebih rendah dibandingkan variabel IDR/USD, baik saat menggunakan rasio pembagian data 70:20:10 dan 80:10:10. Selanjutnya, saat rasio pembagian data untuk data latih ditingkatkan menjadi 80% secara konsisten akan mampu untuk meningkatkan akurasi model, karena dapat memberikan informasi historis yang lebih banyak untuk bisa dipelajari oleh model. Penambahan jumlah layer dari dua menjadi 3 tidak

akan selalu meningkatkan performa model, bahkan pada beberapa skenario pengujian justru membuat nilai evaluasi MSE, RMSE, dan MAPE menjadi naik.

Berdasarkan seluruh skenario telah dilakukan, konfigurasi terbaik diperoleh saat menggunakan fitur indeks DJIA dengan rasio pembagian data 80:10:10 dan arsitektur dua lapisan dengan nilai unit 32 dan 64, yang mendapatkan nilai evaluasi MAPE terendah yaitu 0.6186%. Pengujian yang juga dilakukan dengan variasi *learning rate* dan *dropout rate* juga menunjukkan bahwa kombinasi *learning rate* 0,01 dan *dropout rate* 0,01 merupakan kombinasi konfigurasi yang paling optimal untuk *dataset*. Penurunan *learning rate* dan peningkatan *dropout rate* yang telah dicoba juga cenderung lebih menurunkan performa model, karena proses pembelajaran akan menjadi lebih lambat atau terlalu tereduksi oleh regulasi. Dari seluruh skenario penggunaan fitur, proporsi data latih, serta kompleksitas model adalah faktor utama dalam mendapatkan prediksi nilai IHSG yang lebih akurat.

Tabel 2. Hasil Evaluasi Seluruh Skenario

No	Split Data	Jumlah Layer dan Unit Model	<i>Learning Rate</i>	<i>Dropout Rate</i>	Fitur dan Target Data	MSE	RMSE	MAPE
1	70:20:10	32, 64	0.01	0.1	IHSG & IDR/USD	33154.9317	182.085	2.2221 %
2	70:20:10	32, 64, 128	0.01	0.1	IHSG & IDR/USD	16044.758	126.6679	1.4228 %
3	80:10:10	32, 64	0.01	0.1	IHSG & IDR/USD	5161.3371	71.8424	0.763 %
4	80:10:10	32, 64, 128	0.01	0.1	IHSG & IDR/USD	8854.3355	94.0975	1.0341 %
5	70:20:10	32, 64	0.01	0.1	IHSG & DJIA	5951.8482	77.1482	0.8414 %
6	70:20:10	32, 64, 128	0.01	0.1	IHSG & DJIA	13197.389	114.8799	1.1792 %
7	80:10:10	32, 64	0.01	0.1	IHSG & DJIA	3226.2419	56.8	0.6186 %
8	80:10:10	32, 64, 128	0.01	0.1	IHSG & DJIA	3568.0329	59.733	0.6514 %

No	Split Data	Jumlah Layer dan Unit Model	<i>Learning Rate</i>	<i>Dropout Rate</i>	Fitur dan Target Data	MSE	RMSE	MAPE
9	70:20:10	32, 64	0.01	0.1	IHSG, USD/IDR, & DJIA	19794.5749	140.6932	1.793 %
10	70:20:10	32, 64, 128	0.01	0.1	IHSG, USD/IDR, & DJIA	8825.1799	93.9424	1.0323 %
11	80:10:10	32, 64	0.01	0.1	IHSG, USD/IDR, & DJIA	10984.0777	104.805	1.2493 %
12	80:10:10	32, 64, 128	0.01	0.1	IHSG, USD/IDR, & DJIA	6247.8236	79.0432	0.8315 %
13	80:10:10	32, 64	0.001	0.1	IHSG & DJIA	8269.7124	90.938	0.9812 %
14	80:10:10	32, 64	0.01	0.2	IHSG & DJIA	12017.4913	109.6243	1.2876 %

No	Split Data	Jumlah Layer dan Unit Model	<i>Learning Rate</i>	<i>Dropout Rate</i>	Fitur dan Target Data	MSE	RMSE	MAPE
15	80:10:10	32, 64	0.001	0.2	IHSG & DJIA	11742.7422	108.3639	1.1773 %

DAFTAR PUSTAKA

- [1] K. P. Nurahmad, "Awal Tahun 2025 Investor Pasar Modal Lampau 15 Juta," Bursa Efek Indonesia. Accessed: Oct. 01, 2025. [Online]. Available: <https://www.idx.co.id/id/berita/siaran-pers/2314>
- [2] K. P. Nurahmad, "Capital Market Data Reflects Trust from Investors," Indonesia Stock Exchange. Accessed: Oct. 01, 2025. [Online]. Available: <https://www.idx.co.id/en/news/press-release/2418>
- [3] C. Zhao, L. Kang, X. Xi, S. Du, and J. Li, "Investor sentiment and stock market volatility: Exploring the relationship using sentiment analysis of stock bar comments," *Finance Research Open*, vol. 1, no. 3, pp. 1–12, Sep. 2025, doi: 10.1016/j.finr.2025.100016.
- [4] P. L. T. Nguyen, R. Alsakka, and N. Mantovan, "Political preferences and stock markets," *International Review of Financial Analysis*, vol. 90, Nov. 2023, doi: 10.1016/j.irfa.2023.102910.

- [5] S. Adi and L. Ismawati, "PENGARUH HARGA EMAS DUNIA, RATA-RATA INDUSTRI DOW JONES, DAN INDEKS SHANGHAI TERHADAP INDEKS HARGA SAHAM GABUNGAN PERIODE 2017-2021," *Jurnal Eko-Bisma*, vol. 2, no. 1, pp. 156–166, 2023, doi: <https://doi.org/10.58268/eb.v2i1.34>.
- [6] F. Purwatiningsih and S. Sriyono, "Pengaruh Inflasi, Produk Domestik Bruto dan Nilai Tukar Rupiah terhadap Indeks Harga Saham Gabungan di Bursa Efek Indonesia Periode Januari 2016-Desember 2021," *Innovative Technologica: Methodical Research Journal*, vol. 2, no. 1, Mar. 2023, doi: 10.47134/innovative.v2i1.
- [7] A. Yusuf, "PREDIKSI INDEKS HARGA SAHAM GABUNGAN (IHSG) MENGGUNAKAN LONG SHORT-TERM MEMORY," *Jurnal Epsilon*, vol. 15, no. 2, pp. 124–132, 2021, [Online]. Available: <http://ppjp.ulm.ac.id/journals/index.php/epsilon>
- [8] A. Rahmadeyan and Mustakim, "Long Short-Term Memory and *Gated Recurrent Unit* for Stock Price Prediction," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 204–212. doi: 10.1016/j.procs.2024.02.167.

- [9] A. S. Saud and S. Shakya, "Analysis of look back period for stock price prediction with RNN variants: A case study on banking sector of NEPSE," in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 788–798. doi: 10.1016/j.procs.2020.03.419.
- [10] A. I. Purba, "PERBANDINGAN HARGA SAHAM DAN LIKUIDITAS SEBELUM DAN SESUDAH PEMECAHAN SAHAM (STUDY PADA PERUSAHAAN GO PUBLIC YANG MELAKUKAN PEMECAHAN SAHAM DI BURSA EFEK INDONESIA)," *Jurnal Mutiara Akuntansi*, vol. 2, no. 1, pp. 32–51, Apr. 2017.
- [11] L. A. Sari and H. E. Riwayati, "Analisis Faktor Internal dan Eksternal Perusahaan Terhadap Harga Saham," *JURNAL MANAJEMEN DAN PERBANKAN (JUMPA)*, vol. 11, no. 1, pp. 37–49, Feb. 2024.
- [12] R. N. Hidayati, "ANALISIS VOLATILITAS IHSG: PENGARUH SUKU BUNGA DAN NILAI TUKAR DALAM DINAMIKA PASAR SAHAM INDONESIA," *Bisnis dan Pendidikan*, vol. 4, no. 5, 2024, doi: 10.17977/um066.v4.i5.2024.4.

- [13] G. A. Kasi, J. E. Tulung, and F. J. Tumewu, "REAKSI PASAR MODAL SEBELUM DAN SESUDAH PENGUMUMAN RESESI EKONOMI INDONESIA 2020 PADA INDUSTRI PERBANKAN YANG TERDAFTAR DI BEI," *Jurnal EMBA*, vol. 10, no. 3, pp. 996–1003, Jul. 2022.
- [14] D. A. Fahrini, A. D. Legowati, and A. Fitriyanto, "Analisis Pergerakan Harga Saham pada Jakarta Islamic Index Tahun 2019-2023 Secara Fundamental," *Jurnal Ilmiah Ekonomi Islam*, vol. 10, no. 02, pp. 1871–1878, 2024, doi: 10.29040/jiei.v10i2.13381.
- [15] M. Ahyaruddin, D. Widiarsih, and D. Winarso, "Pengaruh Psikologi Investor Terhadap Volume Perdagangan Saham (Studi Empiris Pada Indeks Saham LQ45 Yang Terdaftar di BEI)," *Jurnal Akuntansi & Ekonomika*, vol. 7, no. 2, pp. 121–131, Dec. 2017.
- [16] M. Sinurat, D. Gunawan, and A. Syahputra, *Pasar Modal*, 1st ed. Jl. Cempaka No. 25 Padang Sidempuan 22725: PT Inovasi Pratama Internasional, 2022.
- [17] I. Indriyani and E. N. Utomo, "Determinan Indek Harga Saham Gabungan Pada Perusahaan Terdaftar Di BEI Tahun 2013-2020," *Balance Vocation Accounting Journal*, vol. 5, no. 1, pp. 49–63, 2013.

- [18] J. E. Putra, S. Na'afi, D. M. Widiniarsih, I. Baidlowi, and S. M. Basannang, "FAKTOR-FAKTOR YANG MEMPENGARUHI ANJLOKNYA IHSG," *JURNAL LENTERA BISNIS*, vol. 14, no. 2, pp. 2377–2389, Jun. 2025, doi: 10.34127/jrlab.v14i2.1587.
- [19] A. Rahmawati and M. M. Nugroho, "Pengaruh Penurunan Ihsg Dan Loss Aversion Bias Terhadap Keputusan Investasi Dengan Literasi Keuangan Sebagai Pemoderasi," *Balance: Jurnal Akuntansi dan Manajemen*, vol. 4, no. 2, pp. 1032–1042, 2025.
- [20] K. Aman, M. Fadli, and D. N. R, "SYSTEMATIC LITERATURE REVIEW: TREN PERKEMBANGAN PENELITIAN FAKTOR YANG MEMPENGARUHI PERGERAKAN INDEKS HARGA SAHAM GABUNGAN (IHSG)," *Blantika Multidisciplinary Journal*, vol. 2, no. 9, pp. 211–225, Jul. 2024.
- [21] I. K. B. Dwijaya and A. A. R, "The Dow Jones Industrial Average as a Moderator in the Relationship Between Macroeconomic Variables and the JCI," *Journal of Trends Economics and Accounting Research*, vol. 5, no. 4, pp. 464–472, 2025, doi: 10.47065/jtear.v5i4.1886.

- [22] S. Bahloul, M. Mroua, and N. Naifar, "The impact of macroeconomic and conventional stock market variables on Islamic index returns under regime switching," *Borsa Istanbul Review*, vol. 17, no. 1, pp. 62–74, Mar. 2017, doi: 10.1016/j.bir.2016.09.003.
- [23] A. Latif, Z. Z. Hidayah, and D. R. Afandi, "Interconnected economies: Assessing the impact of major global stock exchanges and macroeconomic factors on the Indonesian stock market," *Journal of Enterprise and Development (JED)*, vol. 6, no. 1, pp. 237–247, 2024.
- [24] M. R. Bakhtiar and T. Purwani, "DAMPAK INDEKS NIKKEI 225, INDEKS DOW JONES, SUKU BUNGA FED, DAN INFLASI TERHADAP IHSG," *INDICATORS Journal of Economics and Business*, vol. 3, no. 1, pp. 61–70, 2021, [Online]. Available: <http://indicators.iseisemarang.or.id/index.php/jebis>
- [25] A. Thamrin and G. N. Masdjojo, "ANALISIS FAKTOR-FAKTOR PERUBAHAN KURS (VALUTA ASING)," *JIMEA / Jurnal Ilmiah MEA (Manajemen, Ekonomi, dan Akuntansi)*, vol. 9, no. 1, 2025.

- [26] H. F. Febriyanti and S. Delfiani, "Pengaruh Inflasi, Suku Bunga Bank Indonesia, dan Nilai Tukar Rupiah Terhadap Indeks Harga Saham Gabungan (IHSG) Periode 2016 -2020," *Jurnal ManajemenStrategi dan Simulasi Bisnis (JMASSBI*, vol. 4, no. 1, pp. 41–51, 2023.
- [27] D. B. H. Boimau, P. Y. Amtiran, R. F. Makatita, and P. E. de Rozari, "PENGARUH INFLASI, NILAI TUKAR RUPIAH DAN HARGA MINYAK DUNIA TERHADAP INDEKS HARGA SAHAM SEKTORAL PADA SEKTOR PROPERTI DAN REAL ESTATE YANG TERDAFTAR DI BURSA EFEK INDONESIA," *Glory: Jurnal Ekonomi & Ilmu Sosial*, vol. 5, no. 1, pp. 25–40, Feb. 2024.
- [28] R. Octovian, "Pengaruh Inflasi, Nilai Tukar Rupiah, Dan Current Ratio (CR) Terhadap Return Saham Pada PT Ace Hardware Indonesia Tbk Periode 2012-2021," *Journal of Management Specialist*, vol. 3, no. 1, pp. 1–11, Jan. 2025.
- [29] A. S. Kazmali and A. Sayar, "Web Scraping: Legal and Ethical Considerations in General and Local Context-A Review," in *Procedia Computer Science*, Elsevier B.V., 2025, pp. 1563–1572. doi: 10.1016/j.procs.2025.04.111.

- [30] S. Dogan and G. Karatas, "Best Python Web Scraping Libraries: Selenium vs BeautifulSoup," AIMultiple. Accessed: Oct. 14, 2025. [Online]. Available: <https://research.aimultiple.com/python-web-scraping-libraries/>
- [31] J. Y. Guyt, H. Datta, and J. Boegershausen, "Unlocking the Potential of Web Data for Retailing Research," *Journal of Retailing*, vol. 100, no. 1, pp. 130–147, Mar. 2024, doi: 10.1016/j.jretai.2024.02.002.
- [32] M. F. Abdi and Yonhendri, "Implementasi Sistem Prediksi Saham Real-Time dengan Integrasi Yahoo Finance API dan Machine Learning di Google Colab: Analisis dan Evaluasi Performa Model," *Jurnal Teknomatika*, vol. 15, no. 01, pp. 25–31, Mar. 2025, doi: <https://doi.org/10.61423/teknomatika.v15i01.692>.
- [33] B. Gülmez, "Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm," *Expert Syst Appl*, vol. 227, pp. 1–16, Apr. 2023, doi: 10.1016/j.eswa.2023.120346.
- [34] J. K. Mutinda and A. K. Langat, "Stock price prediction using combined GARCH-AI models," *Sci Afr*, vol. 26, pp. 1–14, Sep. 2024, doi: 10.1016/j.sciaf.2024.e02374.

- [35] F. Fauziah, Y. I. Ningsih, and E. Setiarini, "Analisis Peramalan (Forecasting) Penjualan Jasa Pada Warnet Bulian City di Muara Bulian," *Eksis: Jurnal Ilmiah Ekonomi dan Bisnis*, vol. 10, pp. 61–67, 2019.
- [36] A. Muhtar, D. C. Ningrum, and R. M. A. Hutagaol, "Penerapan *Time Series* Forecasting untuk Memprediksi Pertumbuhan Ekonomi Indonesia 2024," *Data Sciences Indonesia (DSI)*, vol. 3, no. 2, pp. 79–89, May 2024, doi: 10.47709/dsi.v3i2.3263.
- [37] D. I. Hamin, "Analisis Laporan Keuangan Secara Historis Dan Forecasting (Studi Kasus Pada PT. Martina Berto Tbk Tahun 2020-2023)," *JURNAL ILMIAH MANAJEMEN DAN BISNIS*, vol. 7, no. 1, pp. 467–478, May 2024, [Online]. Available: <http://ejurnal.ung.ac.id/index.php/IJMB>
- [38] D. Ditania, A. Siahainenia, and F. Matuankotta, "Analisa Peramalan Jumlah Produksi Batako Pada Usaha Batako Papa Press Di Kota Ambon," *JURNAL ADMINISTRASI TERAPAN*, vol. 3, no. 2, pp. 365–374, Sep. 2024.
- [39] H. Yulius and I. Yetti, "Peramalan Kebutuhan Manajemen Logistik Pada Usaha Depot Air Minum Isi Ulang Al-Fitrah," *Jurnal Edik Informatika*, vol. 1, no. 1, pp. 5–14, 2014, doi: 10.22202/jei.2014.v1i1.1430.

- [40] P. J. Brockwell, "Time Series Analysis," in *International Encyclopedia of Education*, 3rd ed., P. Peterson, E. Baker, and B. McGaw, Eds., Reference Work, 2010, pp. 474–481.
- [41] A. M. F. Shadiq, I. Irwan, and K. Nurfadilah, "Analisis Runtun Waktu untuk Peramalan Banyaknya Kejadian Kecelakaan Lalu Lintas Di Kabupaten Soppeng," *Jurnal Matematika dan Statistika serta Aplikasinya*, vol. 13, no. 1, pp. 56–68, 2025.
- [42] Dharaneishvc, "Components of Time Series Data," GeeksforGeeks. Accessed: Oct. 15, 2025. [Online].
- [43] H. Kurniawan, A. S. W. U., and R. W. Tambunan, "Potensi AI dalam Meningkatkan Kreativitas dan Literasi dalam Pembelajaran Bahasa Indonesia," *JAMI: Jurnal Ahli Muda Indonesia*, vol. 5, no. 1, pp. 10–17, Jun. 2024.
- [44] S. Saepudin, S. Nana, M. M. Muhamad, and A. A. Haryanto, "ANALISIS KINERJA YOLOV8 OPTIMALISASI ROBOFLOW UNTUK DETEKSI EKSPRESI WAJAH EMOSIONAL DENGAN MACHINE LEARNING," *NARATIF: Jurnal Ilmiah Nasional Riset Aplikasi dan Teknik Informatika*, vol. 06, no. 2, pp. 115–124, Dec. 2024.

- [45] C. R. China, "Five types of machine learning you need to know," IBM. Accessed: Oct. 16, 2025. [Online]. Available: <https://www.ibm.com/id-id/think/topics/machine-learning-types>
- [46] D. Bergmann, "What is deep learning?," IBM. Accessed: Oct. 16, 2025. [Online]. Available: <https://www.ibm.com/think/topics/deep-learning>
- [47] C. Stryker, "What is a Recurrent Neural Network (RNN)?," IBM. Accessed: Oct. 17, 2025. [Online]. Available: <https://www.ibm.com/id-id/think/topics/recurrent-neural-networks>
- [48] "Apa Itu Penyetelan *Hyperparameter*?," Amazon Web Services. Accessed: Oct. 19, 2025. [Online]. Available: <https://aws.amazon.com/id/what-is/hyperparameter-tuning/>
- [49] B. Marietta, R. Santoso, and A. A. Sa'adah, "PERAMALAN NILAI TUKAR RUPIAH TERHADAP DOLLAR AMERIKA DENGAN METODE LONG SHORT-TERM MEMORY DAN *GATED RECURRENT UNIT*," *Jurnal Gaussian*, vol. 14, no. 1, pp. 13–22, Feb. 2025, doi: 10.14710/j.gauss.14.1.13-22.

- [50] S. R. Dubey, S. K. Singh, and B. B. Chaudhuri, "Activation functions in deep learning: A comprehensive survey and benchmark," *Neurocomputing*, vol. 503, pp. 92–108, Sep. 2022, doi: 10.1016/j.neucom.2022.06.111.
- [51] D. G. McMillan, "The Time-Varying Relation between Stock Returns and Monetary Variables," *Journal of Risk and Financial Management*, vol. 15, no. 1, Jan. 2022, doi: 10.3390/jrfm15010009.
- [52] Y. Anisa, M. Hafiz, and N. Novita, "Pengembangan Model Prediksi Harga Saham Dengan Menggunakan Regresi Linear Berganda Pada Saham BRI," *JISTech (Journal of Islamic Science and Technology)*, vol. 9, no. 2, p. 191, Dec. 2024, doi: 10.30829/jistech.v9i2.22213.
- [53] Y. S. Kim, M. K. Kim, N. Fu, J. Liu, J. Wang, and J. Srebric, "Investigating the impact of data normalization methods on predicting electricity consumption in a building using different artificial neural network models," *Sustain Cities Soc*, vol. 118, pp. 1–12, Jan. 2025, doi: 10.1016/j.scs.2024.105570.

- [54] G. I. Marthasari, S. A. Astiti, and Y. Azhar, "Prediksi Data Time-series menggunakan Jaringan Syaraf Tiruan Algoritma Backpropagation Pada Kasus Prediksi Permintaan Beras," *Jurnal Informatika: Jurnal pengembangan IT (JPIT)*, vol. 6, no. 3, 2021.
- [55] P. Foroutan and S. Lahmiri, "Deep learning systems for forecasting the prices of crude oil and precious metals," *Financial Innovation*, vol. 10, no. 1, pp. 1–40, Dec. 2024, doi: 10.1186/s40854-024-00637-z.

BIODATA PENULIS



Rizki Baehtiar Afandi

Penulis merupakan praktisi dan akademisi bidang Informatika dari Universitas Pembangunan Nasional "Veteran" Jawa Timur dengan spesialisasi mendalam di bidang *Machine Learning* (ML). Sebagai alumni program Bangkit Academy 2024 pada jalur *Machine Learning*, ia memiliki keahlian kuat dalam analisis data, pemrosesan runtun waktu (*time series*), dan pemodelan prediktif menggunakan *Deep Learning*. Pemahaman teoretis serta keterampilan praktisnya dalam merancang arsitektur jaringan saraf tiruan menjadi landasan utama dalam penulisan buku ini, khususnya pada implementasi dan optimasi algoritma *Gated Recurrent Unit* (GRU) untuk memproyeksikan pergerakan Indeks Harga Saham Gabungan (IHSG).



I Gede Susrama Mas Diyasa

Penulis merupakan akademisi dan peneliti di bidang Sistem Informasi yang aktif dalam pengembangan teknologi informasi, transformasi digital, dan kecerdasan buatan (*Artificial Intelligence*). Serta mengajar pada Program Studi Sistem Informasi, Program Magister Manajemen, dan Program Doktor Ilmu Manajemen. Pengalaman akademik dan penelitiannya memperkaya pembahasan buku ini, khususnya pada aspek bisnis, inovasi, dan transformasi digital.