

EVALUASI MODEL GRU UNTUK PREDIKSI IHSG MENGGUNAKAN FITUR INDEKS DJIA

Rizki Bahtiar Afandi¹, I Gede Susrama Mas Diyasa², Fetty Tri Anggraeny³

^{1,2,3} Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia
¹22081010033@student.upnjatim.ac.id, ²igsusrama.if@upnjatim.ac.id, ³fettyanggraeny.if@upnjatim.ac.id

Abstrak

Pergerakan Indeks Harga Saham Gabungan (IHSG) sangat dinamis dan volatil karena dipengaruhi oleh berbagai faktor makroekonomi domestik dan global, sehingga diperlukan model prediksi yang akurat. Penelitian ini memiliki tujuan untuk mengevaluasi kinerja model GRU dalam memprediksi nilai IHSG dengan menambahkan fitur variabel makroekonomi global, yaitu indeks DJIA. Data yang digunakan pada penelitian ini adalah data time series harian nilai IHSG dan indeks DJIA dari periode 2004-2024 yang didapatkan dari proses scrapping menggunakan library YahooFinance. Data kemudian diproses dengan melakukan penggabungan data, normalisasi menggunakan minmaxscaler, serta membentuk struktur data menggunakan sliding window. Metode yang digunakan dalam penelitian ini adalah Gated Recurrent Unit, yang akan diuji menggunakan berbagai rasio pembagian data dan skenario pengujian arsitektur serta hyperparameter. Hasil model terbaik ditemukan pada skenario pengujian dengan rasio pembagian data 80:10:10, dua lapisan GRU dengan unit 32 dan 64, serta learning rate 0,01 yang memperoleh nilai evaluasi MSE 6.392,1084, RMSE 79.9507, dan MAPE 0.9027%. Temuan studi ini menunjukkan bahwa meningkatkan kompleksitas model dengan menambah lapisan tidak selalu akan meningkatkan akurasi dan berpotensi menyebabkan overfitting, sementara pemilihan learning rate yang tepat juga memiliki dampak signifikan pada konvergensi model. Penelitian ini menjelaskan bahwa model GRU yang memiliki konfigurasi seimbangan dan hyperparameter yang optimal akan menghasilkan prediksi IHSG yang lebih akurat. Penambahan fitur makroekonomi global seperti DJIA juga akan berkontribusi baik dalam menangkap pengaruh dinamika pasar global terhadap pasar saham Indonesia.

Kata kunci: *deep learning*, GRU, IHSG, DJIA, *time series*

1. Pendahuluan

Pasar saham adalah salah satu dari berbagai sarana investasi yang saat ini paling diminati diseluruh dunia, termasuk di Indonesia. Hal ini dikarenakan saham menawarkan potensi keuntungan yang cukup baik melalui capitan gain dan dividen serta kemudahan akses yang sangat didukung oleh perkembangan teknologi informasi saat ini. Seluruh perdagangan pasar saham di Indonesia akar terpusat di Bursa Efek Indonesia (BEI) yang menjadi wadah bagi para investor untuk melaksanakan proses transaksi jual beli saham perusahaan yang telah terdaftar. Menurut siaran pers dari BEI, pada awal tahun 2025 jumlah investor di Indonesia saat ini telah mencapai 20,3 juta investor, yang menunjukkan bahwa saham saat ini semakin dipandang sebagai pilihan untuk melakukan investasi jangka panjang (Nurahmad, 2025b).

Indeks Harga Saham Gabungan (IHSG) adalah indikator utama dari kinerja pasar modal di Indonesia yang akan mengakumulasi seluruh nilai harga saham yang telah terdaftar di Bursa Efek Indonesia (BEI), sehingga IHSG akan dijadikan oleh para investor sebagai cerminan dari kesehatan perekonomian nasional. Tahun 2025 menjadi kinerja positif dari

IHSG yang mencatat rekor harga tertinggi mencapai 7.543,503 pada harga penutupan di tanggal 25 Juli 2025 (Nurahmad, 2025a). Hal ini akan mencerminkan rasa percaya diri dari para investor pada prospek pasar saham di Indonesia di tengah tantangan ekonomi global. Namun pergerakan IHSG tidak akan selalu mengalami kenaikan, IHSG dapat mengalami kenaikan dan penurunan tajam yang dipengaruhi oleh berbagai faktor ekonomi global, stabilitas politik, nilai tukar, dan sentimen pasar (Zhao et al., 2025) (Sah, 2025). Fluktuas dari IHSG akan menjadi tantangan untuk para investor dalam melakukan prediksi sehingga perlu adanya prediksi yang akurat dan informasional berbasis data untuk meminimalkan risiko kerugian.

Beberapa penelitian terdahulu telah menjelaskan bahwa IHSG akan dipengaruhi oleh faktor-faktor eksetenal lain. Penelitian terdahulu oleh Adi & Ismawati (2023) menjelaskan bahwa harga emas dunia dan indeks Dow Jones Industrial Average (DJIA) dapat mempengaruhi cukup signifikan terhadap pergerakan IHSG (Adi & Ismawati, 2023). Penelitian ini menggunakan data harga emas dunia dan indeks DJIA yang mempengaruhi harga IHSG dari 2017-2021. Penelitian oleh Khairati & Idamiharti (2024) menjelaskan bahwa harga emas dunia dan

pertumbuhan GDP akan memiliki pengaruh positif dan cukup signifikan terhadap pergerakan IHSG (Khairati & Idamiharti, 2024). Penelitian ini menggunakan data dari tahun 2011-2022 dan 132 observasi. Dari penjelasan beberapa penelitian terdahulu menunjukkan penting untuk mempertimbangkan variabel makroekonomi global pada saat membuat model prediksi pergerakan IHSG.

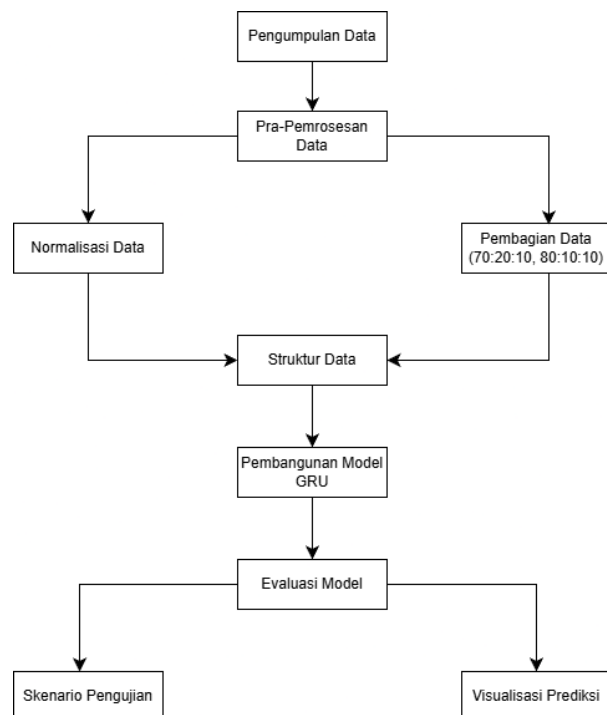
Perkembangan penelitian prediksi harga saham saat ini menggunakan pendekatan machine learning dan deep learning untuk memprediksi data deret waktu (time series). Penelitian terdahulu oleh Yusuf (2021) menjelaskan bahwa algoritma Deep Learning yakni Long Short-Term Memory (LSTM) memiliki performa yang cukup baik saat memprediksi IHSG dengan mendapatkan nilai RMSE sebesar 6,2335, mendapatkan hasil prediksi pada harga 6.765,513 yang pada saat itu harga aktual 6.807,500 dengan menggunakan data dari 16 Februari 2017 - 14 Februari 2020 (Yusuf, 2021). Penelitian lain oleh Prayogi et al. (2024) menjelaskan bahwa algoritma Gated Recurrent Unit (GRU) memiliki performa yang cukup baik saat memprediksi harga saham Bank Central Asia dengan mendapatkan nilai RMSE sebesar 1,039, MSE 1,079, dan MAE 0,842 menggunakan data data dari tahun 2019 - 2024 (Prayogi et al., 2024). Penelitian lain oleh Sofi et al. (2021) menjelaskan bahwa algoritma Gated Recurrent Unit (GRU) memiliki performa yang cukup baik saat memprediksi harga saham KEJU dengan mendapatkan nilai RMSE sebesar 0,032, MSE 0,001, dan MAE 0,024 menggunakan data dari 08 Juni 2019 - 08 Juni 2021 (Sofi et al., 2021).

Berdasarkan penjelasan latar belakang sebelumnya, penelitian ini memiliki tujuan untuk mengembangkan dan mengevaluasi kinerja dari model Gated Recurrent Unit (GRU) untuk memprediksi Indeks Harga Saham Gabungan. Data Indeks Dow Jones Industrial Average (DJIA) juga digunakan untuk menjadi fitur sebagai faktor eksternal dalam penelitian ini. Penelitian ini memiliki fokus untuk mengevaluasi performa model GRU berdasarkan berbagai konfigurasi data, kombinasi variabel, serta arsitektur dan hyperparameter model. Harapan dari penelitian ini adalah untuk memberikan kontribusi dalam menghasilkan model prediksi IHSG yang lebih akurat dan dapat digunakan sebagai pendukung analisis bagi investor dalam memahami dinamika pasar saham di Indonesia secara lebih komprehensif.

2. Metode

Penelitian ini memiliki tujuan untuk melakukan prediksi harga IHSG menggunakan model Gated Recurrent Unit. Gambar 1 menunjukkan tahapan penelitian yang dimulai dari proses pengumpulan data menggunakan cara scrapping dari website Yahoo Finance. Tahapan selanjutnya adalah pra-pemrosesan data yang terbagi menjadi 3 tahapan, yaitu

Penggabungan data, Normalisasi data, dan Pembagian Data. Setelah pra-pemrosesan data, tahapan selanjutnya adalah penyusunan struktur data sebagai input untuk model GRU. Tahapan selanjutnya adalah membangun model GRU untuk memprediksi harga IHSG. Setelah model dibuat, tahapan selanjutnya adalah mengevaluasi model. Model akan dievaluasi menggunakan skenario pengujian berdasarkan berbagai konfigurasi data, kombinasi variabel, serta arsitektur dan hyperparameter model. Tahapan terakhir adalah memvisualisasi hasil prediksi menggunakan data aktual dari data testing.



Gambar 1. Diagram Alir Penelitian

2.1 Pengumpulan Data

Tahapan pengumpulan data adalah proses yang sangat penting pada setiap penelitian, kualitas dan keakuratan data akan sangat berpengaruh langsung terhadap hasil model dalam memprediksi harga saham. Penelitian ini akan menggunakan harga Indeks Harga Saham Gabungan (IHSG) dan Indeks Dow Jones Industrial Average (DJIA). Data yang digunakan diperoleh dari proses web scrapping menggunakan library dari python yakni BeautifulSoup dari web Yahoo Finance. Website Yahoo finance dipilih karena menurut penelitian terdahulu menjelaskan bahwa website ini sering digunakan oleh para peneliti karena memiliki akses yang terbuka dan menyajikan data pasar saham secara global yang lengkap (Abdi & Yonhendri, 2025). Banyak penelitian terdahulu yang menggunakan data dari Yahoo Finance untuk mengembangkan model prediksi time-series dari Yahoo Finance karena

memiliki data yang lengkap (Gülmez, 2023)(Mutinda & Langat, 2024).

Tabel 1. Sample Data IHSG

Price Ticker Date	Adj Close ^JK SE	Close ^JK SE	High ^J KS E	Low ^J KS E	Open ^J KS E	Volume ^JKS E
2004-01-02	704.	704.4	704.	687.9	691.3	1124450
2004-01-03	471	98	498	98	76	0
2004-01-04	725.	725.4	725.4	706.3	706.3	3591550
2004-01-05	444	72	72	70	70	0
2004-01-06	723.	723.9	738.1	717.8	728.7	3979700
.....
.....
.....
2024-12-24	7065	7065.	7120.	7063.	7115.	1106329
2024-12-27	.746	746	576	755	637	00
2024-12-28	7036	7036.	7100.	7024.	7073.	1442776
2024-12-29	.571	571	270	715	375	00
2024-12-30	7079	7079.	7079.	6993.	7026.	1596724
2024-12-31	.905	905	905	072	777	00

Tabel 2. Sample Data DJIA

Price Ticker Date	Adj Close ^DJ	Close ^DJ	High ^DJ	Low ^DJ	Open ^DJ	Volume ^DJ
2004-01-02	10409	10409	1052	1038	1045	168890000
2004-01-03	.85	.85	7.03	4.30	2.74	
2004-01-04	10544	10544	1054	1041	1041	221290000
2004-01-05	.07	.07	4.07	1.85	1.85	
2004-01-06	10538	10538	1054	1049	1054	191460000
.....
.....
.....
2024-12-27	42992	42992	4323	4276	4314	376960000
2024-12-28	.211	.211	8.85	1.55	2.37	
2024-12-29	42573	42573	4286	4226	4286	383300000
2024-12-30	.730	.730	3.85	3.51	3.85	
2024-12-31	42544	42544	4277	4242	4263	383300000
.....	.219	.219	9.69	1.28	6.69	
.....

Data yang diambil dari masing-masing harga saham terdiri dari data harian. Informasi yang diambil dari setiap data memiliki informasi harian seperti tanggal, harga penutupan yang sudah disesuaikan (Adj Close), harga (close), harga (high), harga (low), harga (open), dan volume perdagangan (volume). Data yang tersimpan dimulai dari tanggal 2 Januari 2004 hingga 31 Desember 2024. Total data dari IHSG mencapai 5101 data, sedangkan untuk data DJIA mencapai 5285 data. Setiap data pada Tabel 1 dan 2 akan disimpan dalam format CSV ke masing-masing saham dan akan di proses pada tahapan Pra-pemrosesan data.

2.2 Pra-Pemrosesan Data

Pada tahapan ini, data yang sebelumnya telah dikumpulkan pada tahap sebelumnya akan di proses untuk persiapan ke tahap selanjutnya. Proses pertama

adalah melakukan tranformasi tipe data kolom price ticker date menjadi format tanggal supaya dapat diproses oleh model time-series. Setelah itu, data akan digabungkan berdasarkan tanggal yang sama dan kolom close di masing-masing saham. Kolom close yang digabungkan akan di rename berdasarkan nama harga saham masing-masing. Data digabungkan berdasarkan kolom yang sama karena setiap saham memiliki hari libur perdagangan yang berbeda, sehingga terdapat kekosongan data pada tanggal tertentu yang perlu di hapus.

2.3 Normalisasi Data

Normalisasi data adalah tahapan yang sangat penting dan tidak boleh di hilangkan sebelum data masuk ke proses pelatihan model. Tahapan ini memiliki tujuan untuk menyeragamkan skala antar variabel. Data akan di normalisasi menggunakan metode MinMaxScaler, yakni teknik transformasi data untuk mengubah seluruh nilai pada masing-masing kolom menjadi rentan 0-1 . Menurut penelitian terdahulu menjelaskan bahwa penggunaan teknik MinMaxScaler telah terbukti untuk meningkatkan konvergensi pada model LSTM dan GRU dalam memprediksi harga saham (Kim et al., 2025). Hal ini dikarenakan data yang ternormalisasi akan membuat model lebih cepat dalam menyesuaikan bobot selama pelatihan.

2.4 Pembagian Data

Pembagian data adalah merupakan tahapan penting dalam penelitian ini, dimana dataset akan dibagi menjadi tiga bagian, yaitu train, validation, dan test. Penelitian terdahulu menjelaskan bahwa pemilihan pembagian data sangat mempengaruhi kinerja model dalam memprediksi harga saham menggunakan model Deep Learning (Supri et al., 2023). Penelitian ini akan menggunakan dua skenario pengujian pembagian data. Data akan dibagi dengan rasio 70:20:10 dan 80:10:10 untuk data train, validation, dan testing (Maulana Akbar et al., 2025).

2.5 Struktur Data

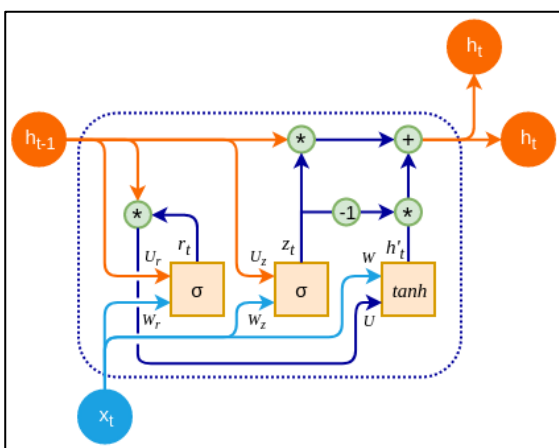
Struktur data adalah tahapan untuk menyesuaikan bentuk dari dataset agar sesuai dengan kebutuhan dari input model GRU. Tahapan ini akan mengubah data yang semula berbentuk dua dimensi menjadi struktur tiga dimensi, yaitu samples, timesteps, dan features. Proses transformasi data ini menggunakan mekanisme dari sliding window dengan cara membentuk urutan data berdasarkan jendela waktu tertentu. Penyesuaian struktur data yang tepat akan berpengaruh langsung terhadap kemampuan model dalam mempelajari pola historis dan menghasilkan prediksi harga IHSG yang lebih akurat (Sharmasaravanan, 2024).

2.6 Pembangunan Model GRU

Model Gated Recurrent Unit (GRU) adalah salah satu dari arsitektur Recurrent Neural Network (RNN) yang dirancang untuk memprediksi data time series. Tujuan dari GRU dikembangkan adalah untuk mengatasi masalah vanishing gradient yang sering terjadi pada RNN konvensional saat mempelajari data dalam jangka panjang. Permasalahan masalah vanishing gradient akan menyebabkan model mengalami kesulitan dalam mempertahankan informasi historis data yang penting. Menggunakan mekanisme gerbang, model GRU akan mampu untuk mempertahankan informasi yang relevan dari waktu sebelumnya secara lebih stabil dan tidak kehilangan banyak data penting.

GRU memiliki mekanisme gating untuk mengatur aliran informasi di dalam jaringan sarafnya. GRU memiliki dua gerbang utama yang digunakan, yaitu reset gate dan update gate yang memiliki fungsi dalam mengontrol informasi lama dan informasi baru pada setiap iterasi. Reset gate akan berfungsi untuk menentukan sejauh mana informasi dari hidden state sebelumnya akan mempengaruhi nilai input saat ini. Update gate akan berfungsi untuk menentukan keseimbangan antara informasi lama dan baru akan dipertahankan dalam memori. Kedua mekanisme ini akan memungkinkan model GRU untuk mempelajari pola temporel secara lebih efisien tanpa mengalami kehilangan informasi historis (Ryan Dana et al., 2025).

Secara arsitektur seperti pada Gambar 2, model GRU terdiri memiliki tiga lapisan utama yaitu lapisan input, lapisan tersembunyi, dan lapisan output. Model GRU memiliki struktur yang lebih sederhana dibandingkan model Long Short-Term Memory (LSTM) karena hanya menggunakan dua gerbang utama (Athallah, 2025). Arsitektur yang sederhana akan membuat model GRU lebih ringan secara komputasi sehingga akan mempercepat proses pelatihan. Hal ini menyebabkan GRU sangat efektif untuk digunakan dalam memprediksi data time series yang bersifat dinamis dan fluktuatif.



Gambar 2. Arsitektur Model GRU

2.7 Evaluasi Model

Setelah semua proses pemodelan dilakukan, perlu melakukan evaluasi terhadap performa model yang telah dilatih menggunakan data yang telah dilakukan proses denormalisasi. Evaluasi model memiliki tujuan untuk mengukur tingkat akurasi dari model dengan cara membandingkan antara hasil prediksi dan nilai aktual menggunakan data testing. Penelitian ini menggunakan metrix evaluasi Mean Squared Error (MSE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Metrix evaluasi model yang digunakan ini sesuai dengan penelitian terdahulu yang menjelaskan penggunaan MSE, MAPE, dan RMSE telah terbukti sangat efektif dalam melakukan evaluasi kinerja model prediksi berbasis deep learning (Foroutan & Lahmiri, 2024) (Najma P. et al., 2025).

3. Hasil dan Pembahasan

Tahapan ini akan menjelaskan tahapan evaluasi kinerja model yang akan digunakan dalam penelitian ini. Penelitian ini hanya akan menggunakan model Gated Recurrent Unit (GRU) karena memiliki kemampuan dalam memprediksi data time-series dengan mempertahankan informasi sebelumnya secara lebih efektif. Model akan dievaluasi dengan membandingkan performa berdasarkan skenario pengujian yang akan ditentukan. Skenario pengujian dilakukan untuk mendapatkan konfigurasi model yang paling optimal dalam memprediksi harga Indeks Harga Saham Gabungan dengan memanfaatkan fitur eksternal Indeks Dow Jones Industrial Average (DJIA).

Beberapa skenario pengujian akan dilakukan untuk melihat pengaruh dari konfigurasi pelatihan dan arsitektur model dalam memprediksi harga IHSG. Skenario pengujian akan meliputi pembagian data dengan pembagian rasio 70:20:10 dan 80:10:10 untuk data latih, validasi dan uji, kemudian timestep di set menggunakan nilai 60. Model GRU akan diimplementasikan menggunakan arsitektur sequential dengan variasi jumlah layer, yaitu menggunakan 2 layer dengan unit 32 dan 64, serta 3 layer dengan unit 32, 64, dan 128. Setiap layer akan menggunakan fungsi aktivasi bawaan GRU (\tanh) dengan menambah nilai dropout yaitu 0.1 untuk mengurangi overfitting, serta penggunaan satu dense layer untuk hasil output prediksi. Proses pelatihan akan dilakukan menggunakan optimizer dari Adam dengan beberapa variasi learning rate yaitu 0.01 dan 0.001, batch size 32, dan epoch 30. Penggunaan epoch 30 akan dikombinasikan dengan memanfaatkan callback EarlyStopping (patience = 5) supaya dapat menghentikan pelatihan secara otomatis saat tidak terdapat peningkatan nilai dari validation loss. Seluruh skenario pengujian yang akan dilakukan pada penelitian ini akan dilakukan evaluasi hasilnya menggunakan metrik Mean Squared Error (MSE),

Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE).

3.1 Analisis Hasil Pengujian Model GRU


Tahapan ini akan menganalisis dari salah satu sampel pengujian model Gated Recurrent Unit dalam memprediksi harga IHSG. Model GRU akan dirancang untuk mempelajari pola temporal dari data IHSG dengan memanfaatkan arsitektur bertingkat (stacked GRU) sehingga model akan mampu untuk menangkap hubungan jangka pendek atau jangka panjang secara lebih optimal. Konfigurasi dari model akan menggunakan nilai dari skenario pengujian yang telah dirancang pada tahapan sebelumnya. Perancangan arsitektur memiliki tujuan untuk mendapatkan model yang stabil, efisien dalam komputasi dan memiliki kemampuan dalam memprediksi pergerakan harga IHSG dengan lebih optimal.

Tabel 3. Sample Arsitektur Model


Layer (type)	Output Shape	Params
gru (GRU)	(None, 60, 32)	3,456
dropout (Dropout)	(None, 60, 32)	0
gru1 (GRU)	(None, 60, 32)	18,816
dropout1 (Dropout)	(None, 64)	0
dense (Dense)	(None, 1)	65

Tabel 3 menjelaskan arsitektur model menggunakan salah satu sample skenario pengujian yang terdiri dari beberapa lapisan GRU yang disusun secara bertingkat. Lapisan awal memiliki fungsi untuk mengekstraksi pola temporal dari data input berbentuk deret waktu. Setiap lapisan dari GRU kan dilengkapi dengan mekanisme dropout untuk mengurangi risiko overfitting. Lapisan akhir dari model GRU memiliki fungsi sebagai lapisan output yang akan menghasilkan satu nilai prediksi harga IHSG. Model akan dilatih menggunakan data latih dan validasi dengan menetapkan fungsi early stopping sebagai penghetian proses pelatihan saat performa model pada data validasi tidak menunjukkan peningkatan yang signifikan.

Gambar 3 menampilkan hasil pelatihan yang menunjukkan nilai loss dan validation loss mengalami tren penurunan signifikan pada beberapa epoch awal. Hal ini menandakan bahwa model GRU telah mampu untuk mempelajari pola dari data IHSG dengan cukup baik. Semakin bertambahnya epoch, nilai training dan validation loss cenderung stabil dan menandakan tidak ada terjadinya overfitting yang signifikan. Validation loss mendapatkan nilai terendah pada epoch 20 dan menandakan bahwa model mencapai kondisi optimal pada titik tersebut dan bobot terbaik yang didapatkan akan dipertahankan untuk proses prediksi.



Gambar 3. Sample Training dan Validation Loss



Gambar 4. Sample Grafik aktual dan prediksi harga IHSG

Gambar 4 menampilkan grafik perbandingan antara nilai dari data aktual dan hasil prediksi harga IHSG menggunakan data uji. Grafik ini menjelaskan bahwa hasil prediksi model telah mampu untuk mengikuti pola dari pergerakan harga IHSG aktual dan cukup baik. Meskipun pada beberapa periode masih terdapat selisih, secara umum garis prediksi selalu bergerak searah dan mendekati nilai aktual. Hasil ini memberikan arti bahwa model GRU memiliki kemampuan yang sangat baik dalam memprediksi pergerakan IHSG menggunakan data uji.

3.2 Evaluasi Kinerja Model Berdasarkan Skenario Pengujian

Tahapan ini akan melakukan evaluasi seluruh kinerja model GRU pada berbagai skenario pengujian yang telah dirancang sebelumnya. Setiap skenario pengujian akan membandingkan kombinasi split data, jumlah hidden layer & unit GRU, learning date, serta dropout rate dan batch size yang telah ditentukan. Kinerja model akan diuji menggunakan metrix MSE, RMSE, dan MAPE. Ketiga metrix evaluasi akan digunakan untuk membandingkan performa model pada setiap konfigurasi dan arsitektur model.

Berdasarkan Tabel 4 yang menjelaskan hasil evaluasi skenario pengujian, skenario dengan split data 80:10:10, dua lapisan GRU dengan nilai 32 dan 64 unit dan learning rate 0,01 mendapatkan hasil performa yang paling baik dengan nilai metrix MSE 6.392,1084, RMSE 79,9507, dan MAPE 0,9027%. Hasil ini menjelaskan bahwa penggunaan rasio data latih yang lebih besar akan memberikan informasi pola yang lebih kaya dan membuat model lebih mampu untuk mempelajari pola pergerakan IHSG secara lebih optimal. Skenario pengujian yang sama

tetapi menggunakan split data 70:20:10 menghasilkan performa yang lebih rendah dengan nilai RMSE dari rentan 107.737-117.1688. Hasil ini mengindikasikan bahwa keterbatasan rasio data latih akan menghambat kemampuan dari model dalam menangkap pola pergerakan secara menyeluruh.

Tabel 4. Hasil Evaluasi Skenario Pengujian

Split Ratio	Unit GRU	Learning Rate	Drop out Rate	MSE	RMS E	MA PE (%)
70:20:10	32,64	0,01	0.1	11607.2555	107.737	1.1646
80:10:10	32,64	0,01	0.1	6392.1084	79.9507	0.9027
70:20:10	32,64, 128	0,01	0.1	12129.7134	110.135	1.2087
80:10:10	32,64, 128	0,01	0.1	6967.6938	83.4727	0.8927
70:20:10	32,64	0,001	0.1	12007.5976	109.5792	1.2257
80:10:10	32,64	0,001	0.1	7503.3242	86.6217	0.9374
70:20:10	32,64, 128	0,001	0.1	13728.5387	117.1688	1.2877
80:10:10	32,64, 128	0,001	0.1	11474.4024	107.186	1.1941

Pengujian terdapat juga pada variasi jumlah unit GRU yang mendapatkan hasil bahwa menambah lapisan GRU dengan nilai 32,64,128 tidak selalu memberikan peningkatan kinerja model. Beberapa skenario pengujian yang menggunakan tiga lapisan GRU mendapatkan nilai MSE, RMSE, dan MAPE lebih tinggi daripada model yang menggunakan dua lapisan GRU. Kondisi ini dapat diartikan bahwa model yang memiliki kompleksitas yang terlalu tinggi malah berpotensi untuk kesulitan dalam menggeneralisasi terhadap data uji. Hasil ini menjelaskan bahwa pemilihan jumlah lapisan dan unit GRU yang seimbang dapat menjadi faktor penting dalam membangun model untuk mendapatkan prediksi yang baik

Nilai learning rate juga cukup berpengaruh terhadap kinerja model yang terlihat cukup signifikan pada hasil pengujian. Penggunaan learning rate 0,01 secara umum akan menghasilkan performa yang lebih baik dibandingkan learning rate 0,001, dimana saat data di bagi pada rasio 70:20:10 maupun 80:10:10. Learning rate yang terlalu kecil dapat menyebabkan proses pembaruan bobot berjalan lebih lambat sehingga model kurang optimal dalam menemukan solusi terbaik. Hasil ini tercermin dari nilai error yang cenderung lebih tinggi pada skenario dengan learning rate 0,001.

4. Kesimpulan

Penelitian ini memiliki tujuan untuk mengevaluasi kinerja model Gated Recurrent Unit (GRU) dalam memprediksi pergerakan Indeks Harga Saham Gabungan (IHSG) dengan memanfaatkan data historis dan variabel eksternal Dow Jones Industrial Average (DJIA). Hasil penelitian menunjukkan bahwa konfigurasi terbaik diperoleh pada rasio data

80:10:10, dua lapisan GRU (32 dan 64 unit), serta learning rate 0,01 dengan nilai MSE 6392,1084, RMSE 79,9507, dan MAPE 0,9027%. Hasil ini menjelaskan bahwa penggunaan rasio data latih yang lebih besar akan mampu untuk meningkatkan kemampuan model dalam mempelajari pola historis secara lebih optimal. Dengan demikian, pembagian data menjadi faktor penting dalam menghasilkan prediksi yang stabil dan akurat.

Pada sisi arsitektur, peningkatan kompleksitas model tidak selalu dapat meningkatkan performa, dimana penggunaan tiga lapisan GRU justru menghasilkan error yang lebih tinggi akibat indikasi overfitting. Selain itu, learning rate 0,01 terbukti lebih efektif dibandingkan 0,001 karena mampu mempercepat konvergensi dan menghasilkan error yang lebih rendah. Hasil ini menegaskan bahwa keseimbangan antara data, arsitektur, hyperparameter, serta pemilihan fitur menjadi kunci utama dalam membangun model prediksi time series yang optimal. Penelitian selanjutnya dapat dikembangkan dengan optimasi hyperparameter menggunakan metode seperti Bayesian Optimization dan Particle Swarm Optimization untuk meningkatkan akurasi prediksi.

Daftar Pustaka:

Abdi, M. F., & Yonhendri. (2025). Implementasi Sistem Prediksi Saham Real-Time dengan Integrasi Yahoo Finance API dan Machine Learning di Google Colab: Analisis dan Evaluasi Performa Model. *Jurnal Teknomatika*, 15(01), 25–31. <https://doi.org/https://doi.org/10.61423/teknomatika.v15i01.692>

Adi, S., & Ismawati, L. (2023). PENGARUH HARGA EMAS DUNIA, RATA-RATA INDUSTRI DOW JONES, DAN INDEKS SHANGHAI TERHADAP INDEKS HARGA SAHAM GABUNGAN PERIODE 2017-2021. *Jurnal Eko-Bisma*, 2(1), 156–166. <https://doi.org/https://doi.org/10.58268/eb.v2i1.34>

Athallah, M. N. (2025). Perbandingan Metode CNN-LSTM dengan Xception-Gated Recurrent Unit pada Image Caption Berbahasa Indonesia. *JUSTIN (Jurnal Sistem Dan Teknologi Informasi)*, 13(2), 307–312. <https://doi.org/10.26418/justin.v13i2.88615>

Foroutan, P., & Lahmiri, S. (2024). Deep learning systems for forecasting the prices of crude oil and precious metals. *Financial Innovation*, 10(1), 1–40. <https://doi.org/10.1186/s40854-024-00637-z>

Gülmez, B. (2023). Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm. *Expert Systems with Applications*, 227, 1–16. <https://doi.org/10.1016/j.eswa.2023.120346>

- Khairati, Z., & Idamiharti. (2024). PENGARUH FAKTOR EKSTERNAL TERHADAP IHSG DI BURSA EFEK INDONESIA. *JAMBURA*, 7(2), 963–972. <https://doi.org/https://doi.org/10.37479/jimb.v7i2.27500>
- Kim, Y. S., Kim, M. K., Fu, N., Liu, J., Wang, J., & Srebric, J. (2025). Investigating the impact of data normalization methods on predicting electricity consumption in a building using different artificial neural network models. *Sustainable Cities and Society*, 118, 1–12. <https://doi.org/10.1016/j.scs.2024.105570>
- Maulana Akbar, B., Anggraeny, F. T., & Prakarsa Mandyartha, E. (2025). Peramalan Harga Minyak Mentah Brent Berbasis Model Prophet dengan Optimasi Tree-Structured Parzen Estimator (TPE). *JiIP (Jurnal Ilmiah Ilmu Pendidikan)*, 8(11), 12777–12782. <https://doi.org/https://doi.org/10.54371/jiip.v8i11.9496>
- Mutinda, J. K., & Langat, A. K. (2024). Stock price prediction using combined GARCH-AI models. *Scientific African*, 26, 1–14. <https://doi.org/10.1016/j.sciaf.2024.e02374>
- Najma P., S., Trimono, & Diyasa, I. G. S. M. (2025). Food Price Prediction Using the Vector Moving Average (VMA) Model in Surabaya and Malang. *Bit-Tech*, 8(1), 146–157. <https://doi.org/10.32877/bt.v8i1.2428>
- Nurahmad, K. P. (2025a, July 25). *Capital Market Data Reflects Trust from Investors*. Indonesia Stock Exchange. <https://www.idx.co.id/en/news/press-release/2418>
- Nurahmad, K. P. (2025b, December). *Menutup Tahun Penuh Prestasi, Pasar Modal Indonesia Optimis Menyongsong Tahun 2026*. Bursa Efek Indonesia. <https://www.idx.co.id/id/berita/siaran-pers/2531>
- Prayogi, K., Gata, W., & Kussanti, D. P. (2024). Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU. *Jutisi: Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, 13, 647–658. <https://doi.org/10.35889/jutisi.v13i1.1910>
- Ryan Dana, A., Trimono, T., & Idhom, M. (2025). Predicting Price and Risk ICBP Stocks Using GRU and VaR. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 19(1), 73–84. <https://doi.org/10.22146/ijccs.101974>
- Sah, I. A. (2025). VOLATILITAS PASAR SAHAM DAN INDIKATOR MAKROEKONOMI: ANALISIS SEKTOR KEUANGAN DI TENGAH OPTIMISME PERTUMBUHAN EKONOMI INDONESIA. *Jurnal Ekonomi, Bisnis Dan Pendidikan*, 5(2). <https://doi.org/https://doi.org/10.17977/um066v5i22025p1>
- Sharmasaravanan. (2024, October 17). *Time-Series Forecasting Using GRU: A Step-by-Step Guide*. Medium. <https://sharmasaravanan.medium.com/time-series-forecasting-using-gru-a-step-by-step-guide-b537dc8dcfba>
- Sofi, K., Sunge, A. S., Riady, S. R., & Kamalia, A. Z. (2021). PERBANDINGAN ALGORITMA LINEAR REGRESSION, LSTM, DAN GRU DALAM MEMREDIKSI HARGA SAHAM DENGAN MODEL TIME SERIES. *SEMINASTIKA*, 3(1), 39–46. <https://doi.org/10.47002/seminastika.v3i1.275>
- Supri, B., Rudianto, Abdurohim, Badriatul Mawadah, & Helmi Ali. (2023). Asian Stock Index Price Prediction Analysis Using Comparison of Split Data Training and Data Testing. *JEMSI (Jurnal Ekonomi, Manajemen, Dan Akuntansi)*, 9(4), 1403–1408. <https://doi.org/10.35870/jemsi.v9i4.1339>
- Yusuf, A. (2021). PREDIKSI INDEKS HARGA SAHAM GABUNGAN (IHSG) MENGGUNAKAN LONG SHORT-TERM MEMORY. *Jurnal Epsilon*, 15(2), 124–132. <https://doi.org/https://doi.org/10.20527/epsilon.v15i2.5026>
- Zhao, C., Kang, L., Xi, X., Du, S., & Li, J. (2025). Investor sentiment and stock market volatility: Exploring the relationship using sentiment analysis of stock bar comments. *Finance Research Open*, 1(3), 1–12. <https://doi.org/10.1016/j.fmr.2025.100016>

Halaman ini sengaja dikosongkan