

## Evaluasi Model GRU dan LSTM untuk prediksi IHSG menggunakan variasi rentang periode data

Rizki Bahtiar Afandi, I Gede Susrama Mas Diyasa\*, Fetty Tri Anggraeny

Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional "Veteran" Jawa Timur  
\*Email: 22081010033@student.upnjatim.ac.id, \*igsusrama.if@upnjatim.ac.id, fettyanggraeny.if@upnjatim.ac.id

### Abstrak

Penelitian ini memiliki tujuan untuk melakukan perbandingan performa antara model LSTM dan GRU dalam memprediksi pergerakan dari nilai Indeks Harga Saham Gabungan menggunakan data deret waktu. Data historis yang digunakan dimulai dari 2 Januari 2010 hingga 30 Desember 2025 yang diperoleh melalui proses web scrapping dari website Yahoo Finance. Model LSTM dan GRU dibangun menggunakan konfigurasi parameter yang sama untuk memastikan bahwa model mendapatkan perbandingan yang adil. Hasil penelitian menunjukkan bahwa model GRU secara konsisten mendapatkan nilai evaluasi MSE, RMSE, dan MAPE yang lebih rendah dibandingkan model LSTM pada seluruh skenario pengujian rentang periode data yang digunakan. Model GRU dan LSTM terbaik terdapat pada skenario pengujian rentang periode data 15 tahun, dengan mendapatkan nilai MSE 4021.6660, RMSE 63.4166, MAPE 0.70% untuk GRU serta MSE 7513.8299, RMSE 86.6824, MAPE 0.94% untuk LSTM. Visualisasi grafik prediksi juga menunjukkan bahwa model GRU lebih mampu untuk mengikuti pola dan tren dari pergerakan IHSG dengan lebih stabil dibandingkan model LSTM. Berdasarkan hasil penelitian ini, dapat disimpulkan bahwa model GRU memiliki performa yang lebih baik dalam memprediksi pergerakan nilai IHSG.

**Kata Kunci:** IHSG; LSTM; GRU; time series; prediksi saham

## *Evaluation of GRU and LSTM Models for IHSG Prediction using Variations in Data Period Ranges*

### Abstract

*This study aims to compare the performance of LSTM and GRU models in predicting movements in the Composite Stock Price Index using time series data. The historical data used covers the period from January 2, 2010, to December 30, 2025, obtained through web scraping from the Yahoo Finance website. The LSTM and GRU models were built using the same parameter configuration to ensure that the models were fairly compared. The results of the study show that the GRU model consistently obtained lower MSE, RMSE, and MAPE evaluation values than the LSTM model in all test scenarios for the data period range used. The best GRU and LSTM models were found in the 15-year data period testing scenario, with MSE values of 4021.6660, RMSE of 63.4166, and MAPE of 0.70% for GRU, and MSE of 7513.8299, RMSE of 86.6824, and MAPE of 0.94% for LSTM. The prediction graph visualization also shows that the GRU model is better able to follow the patterns and trends of the IHSG movement more stably than the LSTM model. Based on the results of this study, it can be concluded that the GRU model has better performance in predicting the movement of the IHSG value.*

**Keywords:** IHSG; LSTM; GRU; time series; stock prediction

### 1. Pendahuluan

Pasar modal saat ini adalah salah satu instrumen investasi yang paling mengalami pertumbuhan signifikan dalam beberapa tahun terakhir di tingkat global ataupun Indonesia. Saham adalah salah satu jenis dari pasar modal yang menjadi pilihan utama bagi banyak investor karena mampu untuk memberikan keuntungan melalui apresiasi harga dan pembagian dividen. Kemajuan teknologi saat ini juga ikut mendorong kemudahan akses terhadap seluruh aktivitas perdagangan saham, sehingga membuat masyarakat dapat ikut berpartisipasi dalam pasar modal dengan lebih cepat. Seluruh aktivitas perdagangan saham yang ada di Indonesia telah dikelola secara terpusat oleh Bursa Efek Indonesia sebagai lembaga resmi untuk memfasilitasi transaksi jual beli saham. Pada akhir tahun 2025 jumlah investor di Indonesia telah mencapai 20,3 juta yang menandakan bahwa masyarakat sudah memandang saham sebagai investasi jangka panjang yang baik (Nurahmad, 2025).

Indeks Harga Saham Gabungan (IHSG) adalah indeks dari pasar saham di Indonesia yang memiliki peran sebagai indikator untuk menggambarkan kondisi dari pasar modal yang ada di Indonesia. IHSG akan memberikan interpretasi dari seluruh kinerja pasar saham yang tercatat di bursa efek Indonesia. Hal ini menyebabkan IHSG sering digunakan oleh para investor saham untuk menilai stabilitas dan perekonomian nasional sebelum dia membeli saham yang ada di Indonesia. Pada tanggal 20 Januari 2025 penutupan sesi 1 posisi IHSG menunjukkan tren positif mencapai nilai 9.155,41 (Wijayanto, 2026). Pencapaian ini menjadi cerminan dari meningkatnya kepercayaan investor terhadap pasar saham di Indonesia walaupun banyak dinamika ekonomi global saat ini.

IHSG memiliki pergerakan yang cukup dinamis serta tidak selalu mengalami kenaikan terus menerus. Nilai indeks bisa mengalami fluktuasi yang cukup signifikan akibat dari pengaruh berbagai faktor, seperti kondisi ekonomi global, nilai tukar mata uang negara tersebut, serta sentimen pasar lokal atau global (Zhao et al., 2025). Ketidakpastian ini akan membuat investor memiliki tantangan dalam menentukan strategi investasi yang cukup efisien. Maka dari itu diperlukan prediksi yang cukup akurat dan memiliki basis dari data historis untuk membantu dalam memahami pola dari pergerakan IHSG sehingga dapat meminimalkan potensi risiko kerugian.

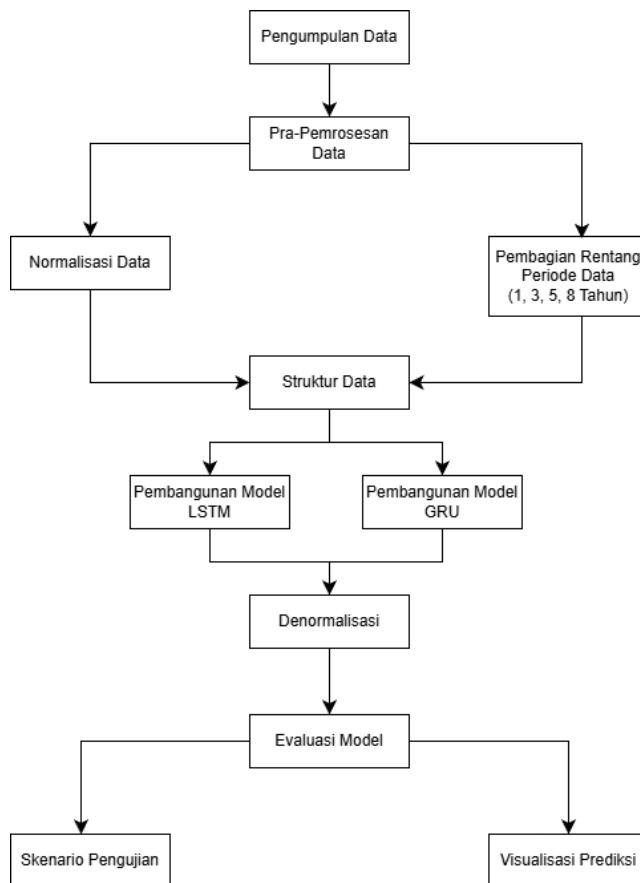
Penelitian yang dilakukan oleh Andromeda & Winarsih pada tahun 2025 mencoba menggunakan metode LSTM dan GRU untuk memprediksi harga close Cryptocurrency. Menggunakan dataset harga historis Bitcoin (BTC) dan Ethereum (ETH) dari 8 Oktober 2024 hingga 13 Oktober 2024 yang medianapkan 79042 data. Kedua model akan dilatih menggunakan learning rate 0.0001 dan 0.001 yang masing-masing terdapat pengujian lagi dengan Batch Size 64 dan 100. Hasil pengujian harga Bitcoin (BTC) terbaik terdapat pada skenario pengujian LR 0.0001 batch size 64 dengan model GRU yang mendapatkan nilai evaluasi MAPE 0.51%, RMSE 304.42, dan  $R^2$  0.9983. Hasil pengujian harga Ethereum (ETH) terbaik terdapat pada skenario pengujian LR 0.001 batch size 64 dengan model GRU yang mendapatkan nilai evaluasi MAPE 0.50%, RMSE 22.53, dan  $R^2$  0.998. Hal ini mendapatkan hasil bahwa model GRU lebih optimal dalam memprediksi harga Cryptocurrency dan Ethereum menggunakan data jangka panjang (Satria Andromeda & Anisa Sri Winarsih, 2025).

Penelitian lain yang dilakukan oleh Rizqiyani dkk. pada tahun 2025 menggunakan model LSTM dan GRU untuk memprediksi harga saham FAST. Data yang digunakan adalah harga saham FAST dari periode 1 Januari 2023 hingga 1 Januari 2025. Data harga saham FAST akan diuji menggunakan model LSTM dan GRU dan pembagian rentang waktu data yang digunakan. Data akan dibagi dalam rentang waktu 3, 6, 12, dan 24 bulan. Model LSTM mendapatkan hasil terbaik saat skenario rentang waktu data 3 bulan dengan nilai evaluasi RMSE 7,6815 dan MAPE 2.10%. Model GRU mendapatkan hasil terbaik saat skenario rentang data 24 bulan dengan nilai evaluasi RMSE 9.7872 dan MAPE 1.91%. Hasil ini mendapatkan temuan bahwa LSTM lebih baik saat digunakan untuk memprediksi data yang menggunakan rentang periode pendek, sedangkan GRU kebalikannya yakni menggunakan rentang periode yang panjang (Rizqiyani et al., 2025).

Penelitian ini memiliki tujuan untuk membandingkan kinerja antara model Long Short Term Memory (LSTM) dengan model Gated Recurrent Unit (GRU) untuk memprediksi pergerakan IHSG. Kedua model akan diuji menggunakan skenario utama yakni pembagian rentang periode data yang digunakan. Penelitian ini dalam melakukan analisis pengaruh dan perbedaan dari masing-masing periode data terhadap tingkat akurasi prediksi model. Model akan dievaluasi menggunakan metrix Mean Squared Error (MSE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE) untuk mengukur kesalahan model dalam memprediksi nilai IHSG. Penelitian ini diharapkan dapat memberikan rekomendasi model dan penggunaan rentang data dengan optimal untuk mendapatkan hasil prediksi IHSG yang cukup baik menggunakan deep learning.

## 2. Metode

Metode penelitian pada penelitian ini tersusun seperti pada Gambar 1. Tahapan dimulai dari pengumpulan data hingga pra-pemrosesan data sebelum masuk ke tahapan struktur data. Tahapan selanjutnya adalah melakukan struktur data agar data sesuai dengan permintaan input dari masing-masing model. Selanjutnya adalah proses pembangunan model yang diikuti proses denormalisasi dan evaluasi model yang telah dibangun. Tahapan terakhir adalah melakukan skenario pengujian untuk mendapatkan hasil model terbaik yang dilanjutkan dengan memvisualisasi hasil prediksi.



Gambar 1. Metodologi Penelitian

### 2.1. Pengumpulan Data

Proses pertama pada penelitian ini adalah mengumpulkan data sebagai input untuk model. Data diambil melalui proses scrapping menggunakan library python yaitu BeautifulSoup melalui website yahoo finance (Faiq Abdi & Yonhendri, 2025) (Alfarisy et al., 2025). Data yang diambil adalah data historis dari IHSG dari tahun 2 Januari 2010 hingga 30 Desember 2025. Tabel 1 adalah sample beberapa data yang telah di scrapping.

Tabel 1. Sample Data IHSG

Price Date	Adj Close	Close	High	Low	Open	Volume
2010-01-04	2575.313	2575.413	2576.056	2532.896	2533.948	18339300
2010-01-05	2605.176	2605.277	2606.069	2575.617	2575.617	57043800
.....	.....	.....	.....	.....	.....	.....
2025-12-29	8644.256	8644.256	8652.183	8545.722	8545.722	334277800
2025-12-30	8646.938	8646.938	8663.668	8584.865	8627.400	308173000

Sumber: Yahoo Finance

### 2.2. Pra-Pemrosesan Data

Tahapan ini akan melakukan proses pada data yang telah dihasilkan melalui proses scrapping. Proses pertama adalah melakukan perubahan format data pada kolom Price Date supaya sesuai dengan tipe data tanggal sehingga siap untuk digunakan dalam analisis deret waktu. Proses selanjutnya adalah melakukan normalisasi data untuk menyamakan rentang nilai dari 0-1 menggunakan metode min-max-scaler (Gotama et al., 2026). Proses normalisasi dilakukan untuk menyelaraskan nilai data yang akan digunakan untuk membuat model LSTM dan GRU (Kim et al., 2025). proses terakhir pada pra-pemrosesan data adalah melakukan pembagian data menjadi beberapa rentang periode sesuai skenario

pengujian untuk mengevaluasi performa model pada panjang periode yang berbeda. Tabel 2 adalah sampe dari data yang telah dinormalisasi.

**Tabel 2.** Sample Normalisasi Data IHSG

Date	Close	Adj Close	High	Low	Open	Volume
2010-01-04	0.051612	0.051612	0.044570	0.051616	0.030638	0.086481
2010-01-05	0.067050	0.067050	0.060134	0.073436	0.052204	0.382376
2010-01-06	0.066027	0.066027	0.068455	0.079613	0.067660	0.340522

Sumber: Data Diolah

### 2.3. Struktur Data

Struktur data adalah tahapan untuk melakukan penyesuaian format dataset supaya lebih kompatibel dengan kebutuhan input pada model LSTM dan GRU. Proses ini akan merubah data yang awalnya berbentuk dua dimensi menjadi representasi tiga dimensi yaitu komponen samples, timesteps, dan features. Proses transformasi ini menggunakan metode sliding window dengan menyusun rangkaian data berdasarkan panjang jendela waktu yang telah ditentukan pada skenario pengujian (Wang et al., 2021). Tabel 3 adalah sample dari salah satu skenario pengujian, yaitu membentuk data menjadi format tiga dimensi yang terdiri dari samples, timesteps, dan features.

**Tabel 3.** Sample Struktur Data IHSG

Shape Data	
Train	(532, 60, 6)
Val	(14, 60, 6)
Test	(14, 60, 6)

Sumber: Data Diolah

### 2.4. Pembangunan Model LSTM

Tahapan pembangunan model Long Short-Term Memory (LSTM) memiliki tujuan untuk mempelajari pola pergerakan data deret waktu berdasarkan hubungan tempolar jangka pendek atau jangka panjang. Model LSTM dibangun menggunakan pemanfaatan arsitektur sel memori yang terdiri dari forget gate, input gate, dan output gate sehingga mampu untuk mengatasi masalah vanishing gradient (Alkahfi et al., 2024)(Krichen & Mihoub, 2025). Data yang sebelumnya telah diproses pada tahapan struktur data akan digunakan sebagai input model, dengan menambahkan jumlah unit, fungsi aktivasi, dan parameter pelatihan lain seperti learning rate dan jumlah epoch. Proses pelatihan model memiliki tujuan untuk meminimalkan nilai kesalahan dari prediksi, sehingga model LSTM bisa menghasilkan prediksi pergerakan IHSG yang lebih akurat dan stabil. Tabel 4 adalah contoh sample arsitektur model LSTM yang digunakan pada penelitian ini, terdiri dari dua lapisan LSTM dengan tambahan hyperparamter dropout rate dan satu lapisan dense sebagai output. Model ini dirancang untuk mempelajari pola temporal dari data IHSG secara efektif.

**Tabel 4.** Sample Arsitektur Model LSTM

**Model: "sequential\_2"**

Layer (type)	Output Shape	Param #
lstm_4 (LSTM)	(None, 60, 32)	4,992
dropout_4 (Dropout)	(None, 60, 32)	0
lstm_5 (LSTM)	(None, 64)	24,832
Dropout_5 (Dropout)	(None, 64)	0
dense_2 (Dense)	(None, 1)	65

- Total params: 29,889 (116.75 KB)
- Trainable params: 29,889 (116.75 KB)
- Non-trainable params: 0 (0.00 B)

Sumber: Data Diolah

## 2.5. Pembangunan Model GRU

Tahapan pembangunan model Gated Recurrent Unit (GRU) memiliki tujuan untuk mempelajari pola pergerakan data deret waktu menggunakan pendekatan jaringan saraf berulang yang lebih sederhana dibandingkan model LSTM. Model GRU memiliki dua mekanisme gerbang utama, yaitu proses update gate dan reset gate yang memiliki fungsi untuk mengatur aliran informasi dalam sel jaringan sehingga lebih mampu untuk menangkap ketergantungan tempola secara efisien (Diqi et al., 2024) (Zhou et al., 2025). Model GRU akan dilatih menggunakan data yang telah melauai proses struktur data sebelumnya dengan menambahkan jumlah unit, fungsi aktivasi, dan parameter pelatihan lain seperti learning rate dan jumlah epoch. Model GRU yang memiliki struktur lebih ringkas diharapkan lebih mampu untuk memberikan prediksi IHSG yang lebih baik dengan waktu komputasi yang lebih efisien. Tabel 5 adalah contoh sample arsitektur model GRU yang digunakan pada penelitian ini, terdiri dari dua lapisan GRU dengan tambahan hyperparameter dropout rate dan satu lapisan dense sebagai output. Model ini telah dirancang untuk mempelajari pola temporal dari data IHSG secara lebih efektif.

**Tabel 5.** Sample Arsitektur Model GRU

**Model: "sequential\_2"**

Layer (type)	Output Shape	Param #
gru_8 (GRU)	(None, 60, 32)	3,840
dropout_8 (Dropout)	(None, 60, 32)	0
gru_9 (GRU)	(None, 64)	18,816
dropout_9 (Dropout)	(None, 64)	0
dense_4 (Dense)	(None, 1)	65

d. Total params: 22,721 (88.75 KB)

e. Trainable params: 22,721 (88.75 KB)

f. Non-trainable params: 0 (0.00 B)

Sumber: Data Diolah

## 2.6. Evaluasi Model

Tahapan terakhir pada penelitian ini adalah melakukan evaluasi model untuk mengukur tingkat akurasi dari hasil prediksi yang telah dihasilkan oleh model LSTM dan GRU. Evaluasi mode pada penelitian ini akan menggunakan metrik evaluasi Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE) (Khan & Osińska, 2023). MSE akan digunakan untuk menghitung rata-rata dalam kuadrat selisih nilai aktual dan nilai prediksi sehingga dapat memberikan penalti yang lebih besar terhadap kesalahan yang bernilai ekstrem. RMSE adalah nilai akar dari MSE yang memiliki tujuan untuk menyajikan nilai kesalahan dalam satuan asli, sehingga lebih mudah untuk diinterpretasikan. Sementara itu nilai MAPE digunakan untuk mengukur tingkat kesalahan prediksi dalam bentuk presentase untuk memudahkan perbandingan performa model.

## 3. Hasil dan Pembahasan

Tahapan ini akan menjelaskan hasil pengujian dan pembahasan dari performa model Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk memprediksi pergerakan Indeks Harga Saham Gabungan (IHSG). Pengujian akan dilakukan menggunakan data historis yang telah melalui tahapan-tahapan pada metode penelitian sebelumnya. Performa dari model akan dilakukan evaluasi menggunakan metrix yang telah ditentukan sebelumnya yakni MSE, RMSE, dan MAPE untuk menilai tingkat akurasi dan kesalahan dalam memprediksi pergerakan IHSG. Visualisasi hasil prediksi dalam bentuk grafik juga akan ditampilkan untuk membandingkan pola dari pergerakan nilai aktual dan hasil prediksi, sehingga mendapatkan gambaran kinerja dari masing-masing model.

### 3.1. Evaluasi Perbandingan

Tahapan ini akan melakukan evaluasi perbandingan antara model LSTM dan GRU yang akan diuji menggunakan konfigurasi arsitektur dan konfigurasi data yang sama. Pengujian dilakukan menggunakan timestep 60, epoch 30, batch size 32, learning rate 0,01, dan dropout rate 0,1 untk

mengurangi risiko overfitting. Model akan menggunakan 2 layer dengan masing-masing unit 32 dan 64. Data dibagi menggunakan rasio 80:10:10 untuk data latih, validasi, dan uji.

**Tabel 6.** Evaluasi perbandingan model

Model	Rentang Periode (Tahun)	MSE	RMSE	MAPE (%)
GRU	3	2833.9697	53.2350	0.97
GRU	5	2966.9022	54.4693	0.93
GRU	10	4483.7297	66.9607	0.85
<b>GRU</b>	<b>15</b>	<b>4021.6660</b>	<b>63.4166</b>	<b>0.70</b>
LSTM	3	5107.1834	71.4646	1.32
LSTM	5	4858.3320	69.7017	1.19
LSTM	10	7733.5646	87.9407	1.14
<b>LSTM</b>	<b>15</b>	<b>7513.8299</b>	<b>86.6824</b>	<b>0.94</b>

Berdasarkan nilai evaluasi yang ditampilkan pada Tabel 6, dapat dilihat bahwa model GRU secara konsisten mendapatkan nilai evaluasi yang lebih rendah daripada model LSTM di semua skenario pengujian. Pada skenario pengujian rentang periode 3 tahun, model GRU mendapatkan nilai MSE 2833.9697, RMSE 53.2350, dan MAPE 0.97% yang menunjukkan tingkat akurasi prediksi yang cukup baik dalam menangkap pola dari pergerakan IHSG jangka pendek. Sebaliknya, model LSTM pada skenario pengujian rentang periode yang sama mendapatkan nilai evaluasi yang lebih besar, model LSTM mendapatkan nilai MSE 5107.1834, RMSE 71.4646, dan MAPE 1.32% yang menunjukkan bahwa model kurang optimal dalam menangkap pola pergerakan IHSG jangka pendek. Perbedaan nilai MSE dan RMSE dari kedua model masih cukup signifikan, model GRU masih mendapatkan keunggulan dibandingkan model LSTM pada periode jangka pendek.

Selanjutnya adalah pengujian menggunakan rentang periode 5 tahun, dimana performa kedua model mengalami peningkatan stabilitas yang baik, dengan mendapatkan nilai MAPE yang semakin kecil untuk kedua model. Model GRU mendapatkan nilai MAPE lebih baik dibandingkan LSTM dengan nilai 0.93% dan 1.19% untuk LSTM. Hasil ini menunjukkan bahwa GRU tetap mampu untuk mempertahankan akurasi dalam memprediksi pergerakan IHSG secara lebih konsisten meskipun rentang periode data yang digunakan diperpanjang. Nilai MSE dan RMSE dari kedua model juga memiliki perbedaan yang cukup signifikan, dimana model GRU masih lebih unggul dibandingkan model LSTM.

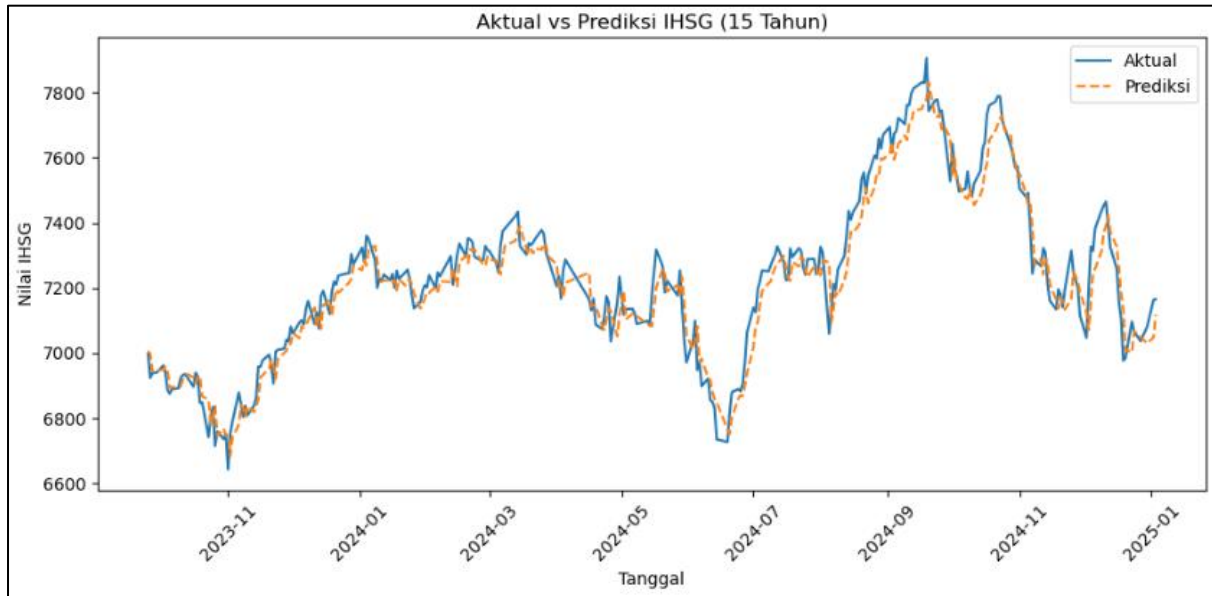
Pengujian selanjutnya adalah menggunakan rentang periode yang lebih panjang yaitu 10 dan 15 tahun. Nilai MSE dan RMSE pada model LSTM dan GRU lebih cenderung mengalami peningkatan yang memiliki indikasi bahwa semakin panjangnya rentang data historis yang digunakan. Jika rentang data yang digunakan semakin panjang, maka kompleksitas pola pergerakan IHSG juga semakin tinggi. Saat nilai MSE dan RMSE dari kedua model meningkat, nilai MAPE pada kedua model tetap cenderung pada kisaran yang lebih rendah. Hal ini menjelaskan bahwa kesalahan prediksi yang dihasilkan oleh kedua model cenderung bersifat relatif kecil dibandingkan dengan nilai asli IHSG.

Perbedaan karakteristik dari ketiga evaluasi model akan menyebabkan interpretasi hasil dari evaluasi menjadi lebih komprehensif. MSE dan RMSE akan lebih sensitif terhadap kesalahan absolut karena melakukan perhitungan berbasis kuadrat selisih antara nilai aktual dan hasil prediksi. Sementara itu, nilai MAPE akan mengukur kesalahan relatif dari prediksi ke dalam bentuk persentase sehingga lebih representatif untuk menilai akurasi prediksi model pada data yang berskala besar seperti IHSG. Meskipun nilai dari MSE dan RMSE tergolong relatif tinggi, nilai MAPE yang rendah akan menunjukkan bahwa model LSTM dan GRU tetap mampu untuk mengikuti tren dari pergerakan IHSG dengan baik, terutama pada model GRU yang menunjukkan performa lebih stabil dan cukup baik.

### 3.2. Grafik Prediksi Model LSTM dan GRU Terbaik

Grafik prediksi yang ditampilkan pada tahapan ini akan digunakan untuk melakukan perbandingan secara visual antara nilai aktual dari IHSG dengan dengan hasil prediksi prediksi yang telah dihasilkan oleh model GRU dan LSTM pada skenario pengujian terbaik di rentang periode data 15 tahun. Visualisasi ini memiliki tujuan untuk menunjukkan sejauh mana masing-masing model mampu

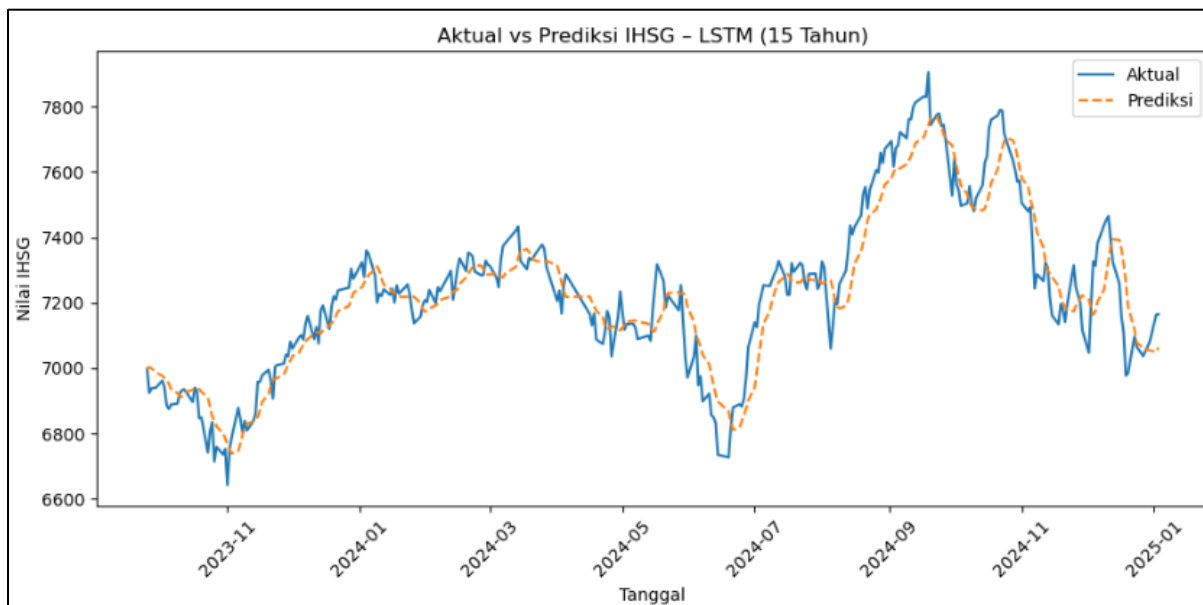
mengikuti pola dari pergerakan IHSG, baik saat kondisi tren naik maupun turun. Perbandingan grafik akan memberikan gambaran yang lebih mendalam tentang kedekatan dari hasil prediksi terhadap data aktual yang tidak sepenuhnya hanya dapat ditampilkan melalui evaluasi metrix. Grafik yang ditampilkan akan menjadi pelengkap penting dalam mengevaluasi performa model secara menyeluruh.



**Gambar 2.** Grafik Prediksi dan Aktual Model GRU

Berdasarkan hasil grafik visualisasi pada Gambar 2, model GRU menunjukkan kemampuannya yang cukup baik dalam mengikuti pola pergerakan dari nilai IHSG aktual, terutama saat menangkap arah tren utama dan perubahan nilai secara bertahap. Garis prediksi dari nilai GRU terlihat lebih halus dan relatif lebih dekat dengan garis aktual, meskipun beberapa masih terdapat selisih pada titik ekstrem ketika terjadi perubahan nilai tajam. Perbedaan ini menjelaskan bahwa model GRU cenderung lebih meredam fluktuasi ekstrem, tetapi akan tetap mampu untuk mempertahankan pola dari pergerakan secara umum. Hasil ini sesuai dengan nilai hasil evaluasi sebelumnya yang menunjukkan nilai MAPE dari model GRU yang relatif rendah.

Gambar 3 yang menampilkan hasil grafik visualisasi prediksi dari model LSTM juga mampu untuk mengikuti tren dari pergerakan IHSG, namun masih memiliki beberapa selisih yang lebih besar pada beberapa periode tertentu. Saat kondisi fluktuasi tajam, hasil prediksi dari model LSTM terlihat mengalami keterlambatan dalam menyesuaikan nilai aktual. Secara umum model LSTM tetap mampu untuk mempresentasikan arah dari pergerakan IHSG secara cukup baik. Perbedaan visual ini akan memperkuat hasil dari evaluasi sebelumnya, dimana model GRU mendapatkan performa yang lebih stabil dan akurat dibandingkan model LSTM pada seluruh periode.



Gambar 3. Grafik Prediksi dan Aktual Model LSTM

#### 4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, mendapatkan kesimpulan bahwa model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) mampu untuk digunakan sebagai prediksi pergerakan dari nilai Indeks Harga Saham Gabungan (IHSG) menggunakan data historis. Hasil evaluasi juga menunjukkan bahwa model GRU secara konsisten lebih memberikan performa yang lebih baik dibandingkan model LSTM pada seluruh skenario pengujian rentang periode data. Hasil ini ditunjukkan pada nilai MSE, RMSE, dan MAPE pada model GRU lebih rendah pada seluruh rentang periode data, baik saat rentang jangka pendek maupun jangka panjang. Keunggulan dari model GRU menunjukkan bahwa model ini mampu untuk melakukan generalisasi dan stabilitas yang cukup baik dalam mempelajari pola temporal dari pergerakan IHSG.

Nilai MSE dan RMSE pada kedua model mengalami peningkatan seiring bertambahnya rentang periode data yang digunakan, namun nilai MAPE masih berada pada kisaran yang relatif cukup rendah. Kondisi ini menjelaskan bahwa kesalahan prediksi yang dihasilkan memiliki sifat yang relatif kecil terhadap nilai aktual IHSG secara keseluruhan. Hasil visualisasi grafik prediksi juga akan memperkuat temuan dari penelitian ini. Model GRU lebih mampu untuk mengikuti pola dan tren dari pergerakan IHSG secara lebih stabil dibandingkan dengan model LSTM, terutama saat kondisi fluktuasi tajam. Hasil ini menjelaskan bahwa model GRU lebih baik untuk digunakan dalam memprediksi pergerakan saham seperti nilai IHSG karena memiliki struktur yang lebih sederhana, sehingga memiliki efisiensi komputasi yang lebih baik untuk mendapatkan nilai akurasi yang lebih tinggi.

#### 5. Ucapan terimakasih

Penulis mengucapkan terima kasih kepada pihak-pihak yang telah memberikan dukungan dan bantuan kepada penulis dalam melaksanakan penelitian ini, baik dalam bentuk fasilitas, data, maupun masukan akademik. Ucapan terima kasih juga disampaikan kepada dosen pembimbing yang telah memberikan arahan selama proses penelitian ini. Penulis juga memberikan apresiasi kepada pihak penyedia data yang bisa digunakan dalam penelitian ini sehingga dapat diselesaikan dengan baik.

#### Daftar Pustaka

Alfarisy, G. A. F., Hoan, R. O., Helmi, Rajab, N. A., & Putra, B. M. K. (2025). Ecommerce-Price-Scraper: Pustaka Ekstraksi Harga E-Commerce Indonesia Melalui Web Scraping. *EQUIVA Journal of Mathematics & Information Technology*, 3(1), 26–33. <https://doi.org/https://doi.org/10.35718/equiva.v3i1>

- Alkahfi, C., Kurnia, A., & Saefuddin, A. (2024). Perbandingan Kinerja Model Berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(4), 1235–1243. <https://doi.org/10.57152/malcom.v4i4.1415>
- Diqi, M., Hiswati, M. E., & Wijaya, N. (2024). Stacked Gated Recurrent Units and Indonesian Stock Predictions: A New Approach to Financial Forecasting. *JURNAL ILMU KOMPUTER DAN TEKNOLOGI(IKOMTI)*, 5(1), 11–17. <http://creativecommons.org/licenses/by/4.0/>
- Faiq Abdi, M., & Yonhendri. (2025). Implementasi Sistem Prediksi Saham Real-Time dengan Integrasi Yahoo Finance API dan Machine Learning di Google Colab. *TEKNOMATIKA*, 15(01), 25–31. <https://doi.org/https://doi.org/10.61423/teknomatika.v15i01.692>
- Gotama, I. G. A. R., Sudipa, I. G. I., Brahma, A. A. G. R. W., Ariantini, M. S., & Wulandari, D. A. P. (2026). Enhanced Stacked GRU Model for Monthly Rice Production Forecasting in Bali Province. *Sinkron*, 10(1), 652–664. <https://doi.org/10.33395/sinkron.v10i1.15715>
- Khan, A. M., & Osińska, M. (2023). Comparing forecasting accuracy of selected grey and time series models based on energy consumption in Brazil and India. *Expert Systems with Applications*, 212, 1–15. <https://doi.org/10.1016/j.eswa.2022.118840>
- 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>
- Krichen, M., & Mihoub, A. (2025). Long Short-Term Memory Networks: A Comprehensive Survey. In *AI (Switzerland)* (Vol. 6, Number 9). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/ai6090215>
- Rizqiyani, E. M., Setiawan, N. Y., & Saputra, M. C. (2025). STUDI KOMPARATIF ALGORITMA LONG SHORT TERM MEMORY (LSTM) DAN GATED RECURRENT UNIT (GRU) DALAM PERAMALAN HARGA SAHAM PT. FAST FOOD INDONESIA TBK (FAST). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 9(11), 1–7. <http://j-ptiik.ub.ac.id>
- Satria Andromeda, R., & Anisa Sri Winarsih, N. (2025). Performance Comparison of LSTM and GRU Methods in Predicting Cryptocurrency Closing Prices. *Sistemasi: Jurnal Sistem Informasi*, 14(1), 366–379. <https://doi.org/https://doi.org/10.32520/stmsi.v14i1.4880>
- Wang, J., Jiang, W., Li, Z., & Lu, Y. (2021). A new multi-scale sliding window lstm framework (Mssw-lstm): A case study for gnn time-series prediction. *Remote Sensing*, 13(16), 1–15. <https://doi.org/10.3390/rs13163328>
- 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.finr.2025.100016>
- Zhou, S., Yang, Z., Yu, Q., & Wang, J. (2025). Grid-Search-Optimized, Gated Recurrent Unit-Based Prediction Model for Ionospheric Total Electron Content. *Technologies*, 13(8). <https://doi.org/10.3390/technologies13080347>
- Nurahmad, K. P. (2025, 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>
- Wijayanto, T. (2026, January 20). IHSG Kembali Cetak Rekor Tertinggi Sepanjang Masa. *Kompas*. <https://www./artikel/ihs-g-kembali-cetak-rekor-tertinggi-sepanjang-masa>