

## PREDIKSI IHSG BERBASIS WEB MENGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM)

I Komang Agus Arta Cahyana<sup>✉</sup>, Ni Gusti Ayu Putu Harry Saptarini,  
Putu Desiana Wulaning Ayu

Prodi Sarjana Terapan TRPL, Jurusan Teknologi Informasi, Politeknik Negeri Bali, Badung, Indonesia

Email: [cahyanaarta07@gmail.com](mailto:cahyanaarta07@gmail.com)

DOI: <https://doi.org/10.46880/jmika.Vol10No1.pp249-259>

### ABSTRACT

The movement of the Composite Stock Price Index (IHSG) is highly dynamic, volatile, and influenced by various external factors, making the forecasting process relatively complex. This study aims to develop a web-based IHSG forecasting system using the Long Short-Term Memory (LSTM) method to support market trend analysis in a more interactive and efficient manner. The dataset was collected from the Yahoo Finance API, consisting of Open, High, Low, Close, and Volume (OHLCV) attributes. The research stages include data preprocessing, normalization using Min-Max Scaling, sequence generation through the sliding window technique, model training, performance evaluation, and web-based system implementation using Streamlit. Hyperparameter tuning was conducted by testing several combinations of window size, hidden units, learning rate, and training epochs to determine the optimal model configuration. The best-performing model was obtained using a window size of 60, 128 hidden units, a learning rate of 0.01, and 64 epochs. The model achieved an RMSE value of 51.9821, an MAE of 39.8241, and a MAPE of 0.5590%, indicating a highly accurate forecasting performance. In addition to producing stable forecasting results, this research also integrates the LSTM model into an interactive web-based application equipped with an analytical dashboard, graphical visualization, model performance evaluation, and batch prediction features. Unlike previous studies that mainly focused on offline model experimentation, this study emphasizes the development of a more practical and user-friendly forecasting system for non-technical users.

**Keyword:** LSTM, IHSG, Time Series Forecasting, Deep Learning, Web-based System.

### ABSTRAK

Pergerakan Indeks Harga Saham Gabungan (IHSG) memiliki karakteristik yang dinamis, fluktuatif, dan dipengaruhi oleh berbagai faktor eksternal sehingga proses prediksi menjadi cukup kompleks. Penelitian ini bertujuan mengembangkan sistem prediksi IHSG berbasis web menggunakan metode Long Short-Term Memory (LSTM) untuk membantu proses analisis pergerakan pasar saham secara lebih cepat dan interaktif. Data penelitian diperoleh dari Yahoo Finance API dengan atribut Open, High, Low, Close, dan Volume (OHLCV). Tahapan pengolahan data meliputi preprocessing, normalisasi menggunakan Min-Max Scaling, pembentukan sequence menggunakan teknik sliding window, pelatihan model, evaluasi performa, serta implementasi sistem berbasis web menggunakan Streamlit. Proses tuning hyperparameter dilakukan dengan menguji beberapa kombinasi window size, hidden unit, learning rate, dan jumlah epoch untuk memperoleh konfigurasi model terbaik. Berdasarkan hasil pengujian, model optimal diperoleh pada penggunaan window size 60, hidden unit 128, learning rate 0.01, dan epoch 64. Model menghasilkan nilai RMSE sebesar 51.9821, MAE sebesar 39.8241, dan MAPE sebesar 0.5590%, yang menunjukkan tingkat akurasi prediksi sangat baik. Selain menghasilkan performa forecasting yang stabil, penelitian ini juga mengintegrasikan model LSTM ke dalam sistem berbasis web interaktif yang dilengkapi dashboard analisis, visualisasi grafik, evaluasi performa model, dan fitur batch prediction. Berbeda dengan penelitian sebelumnya yang umumnya hanya berfokus pada evaluasi model secara offline, penelitian ini menekankan implementasi sistem forecasting yang lebih aplikatif dan mudah digunakan oleh pengguna non-teknis.

**Kata Kunci:** LSTM, IHSG, Prediksi Time Series, Deep Learning, Sistem Berbasis Web.

### PENDAHULUAN

Pasar modal menjadi salah satu komponen penting dalam aktivitas ekonomi karena memiliki peran sebagai sarana investasi. Di Indonesia, kondisi kondisi

pasar direpresentasikan oleh Indeks Harga Saham Gabungan (IHSG) yang menggambarkan perubahan harga saham dari keseluruhan Bursa Efek Indonesia (BEI). Namun, pola pergerakan IHSG cenderung



berubah secara dinamis sehingga proses prediksi menjadi tidak sederhana. Perubahan tersebut dipengaruhi oleh banyak faktor, mulai dari kondisi ekonomi makro, sentimen investor, kebijakan pemerintah, hingga dinamika pasar global. Situasi tersebut menyebabkan data IHSG memiliki karakteristik fluktuatif dan sulit diprediksi menggunakan pendekatan linear sederhana (Joddy, 2025).

Data IHSG termasuk data deret waktu (*Time Series*) karena tersusun berdasarkan periode tertentu dan memiliki ketergantungan antar waktu serta pola yang tidak selalu linear. Dalam beberapa penelitian sebelumnya, metode statistik seperti *Autoregressive Integrated Moving Average* (ARIMA) cukup sering digunakan untuk forecasting pasar saham. Namun, pendekatan statistik tradisional umumnya lebih efektif pada pola data yang relatif stabil dan linear (Mahfud Al et al., 2020). Pada data saham yang memiliki perubahan tren cepat dan volatilitas tinggi, model konvensional sering mengalami kesulitan dalam mempertahankan akurasi prediksi secara konsisten. Oleh sebab itu, pendekatan berbasis Deep Learning mulai banyak digunakan karena dinilai lebih mampu mengenali pola non-linear dan hubungan temporal pada data sekuensial.

Salah satu metode yang cukup banyak diterapkan dalam prediksi pasar saham adalah *Long Short-Term Memory* (LSTM). Arsitektur ini merupakan pengembangan dari *Recurrent Neural Network* (RNN) yang dirancang untuk mempertahankan informasi historis dalam periode yang lebih panjang melalui mekanisme *memory cell* dan *gate*. Kemampuan tersebut membuat LSTM lebih adaptif terhadap data pasar saham yang memiliki dependensi temporal dan pola perubahan kompleks. Penelitian Moghar & Hamiche (2020) menunjukkan bahwa LSTM memiliki performa yang lebih baik dibandingkan pendekatan statistik tradisional dalam memprediksi data saham yang bersifat non-linear. Selain itu, Budiharto (2021) menjelaskan bahwa model LSTM masih mampu mempertahankan kestabilan performa prediksi meskipun pasar mengalami volatilitas tinggi selama pandemi COVID-19 (Budiharto, 2021).

Dalam perkembangan model Recurrent Neural Network, terdapat metode lain seperti Gated Recurrent Unit (GRU) yang memiliki struktur lebih sederhana dibandingkan LSTM. GRU dikembangkan untuk mengurangi kompleksitas komputasi sehingga proses pelatihan model dapat berlangsung lebih cepat. Beberapa penelitian menunjukkan bahwa GRU mampu menghasilkan performa yang kompetitif pada kasus

prediksi time series tertentu (Aryati et al., 2024). Walaupun demikian, penelitian ini tetap menggunakan metode LSTM karena kemampuan *memory cell* pada LSTM dinilai lebih optimal dalam mempertahankan informasi jangka panjang pada data pasar saham. Karakteristik IHSG yang non-linear, volatil, dan memiliki pola historis kompleks membutuhkan model dengan kemampuan memori temporal yang lebih kuat dibandingkan arsitektur yang lebih sederhana.

Berbagai penelitian sebelumnya telah mengembangkan model prediksi saham berbasis LSTM menggunakan pendekatan dan konfigurasi yang berbeda-beda. Penelitian oleh Remetwa et al (2025) menunjukkan bahwa parameter seperti window size, learning rate, dan jumlah epoch memiliki pengaruh signifikan terhadap performa model dalam memprediksi IHSG. Penelitian lain oleh Saepulrohman et al (2025) juga menunjukkan bahwa optimasi model LSTM mampu meningkatkan akurasi forecasting berdasarkan evaluasi RMSE dan MAE. Selain itu, Dqi et al (2024) mengembangkan arsitektur Stacked Bidirectional LSTM untuk meningkatkan kemampuan model dalam memahami pola sequence dari dua arah pemrosesan data.

Meskipun penelitian sebelumnya menunjukkan hasil prediksi yang cukup baik, sebagian besar studi masih berfokus pada tahap eksperimen model dan evaluasi statistik secara offline. Implementasi sistem forecasting yang dapat digunakan secara langsung oleh pengguna masih relatif terbatas. Selain itu, hasil prediksi umumnya hanya ditampilkan dalam bentuk tabel evaluasi tanpa visualisasi interaktif yang memudahkan interpretasi pengguna non-teknis. Padahal, dalam implementasi nyata, sistem prediksi yang mudah diakses dan dipahami memiliki nilai praktis yang lebih tinggi dibandingkan model yang hanya diuji pada lingkungan eksperimen.

Berdasarkan kondisi tersebut, penelitian ini bertujuan membangun sistem prediksi IHSG berbasis web menggunakan metode LSTM. Penelitian tidak hanya berfokus pada pembangunan model forecasting untuk memperoleh tingkat akurasi yang baik, tetapi juga mengintegrasikan model ke dalam aplikasi berbasis web yang dilengkapi dashboard interaktif dan visualisasi grafik. Berbeda dengan penelitian sebelumnya yang umumnya hanya menitikberatkan pada evaluasi model secara offline, penelitian ini menekankan pengembangan sistem forecasting yang lebih aplikatif dan dapat digunakan secara langsung oleh pengguna non-teknis.

Penelitian ini memiliki perbedaan dibandingkan penelitian forecasting saham sebelumnya yang umumnya hanya berfokus pada pengembangan dan

evaluasi model prediksi secara offline. Novelty utama penelitian terletak pada integrasi model Long Short-Term Memory (LSTM) ke dalam sistem berbasis web interaktif yang dilengkapi fitur visualisasi grafik, dashboard monitoring, evaluasi performa model secara real-time, serta simulasi batch prediction. Selain menghasilkan model forecasting dengan tingkat akurasi yang baik, penelitian ini juga menekankan aspek implementasi sistem yang lebih aplikatif dan mudah digunakan oleh pengguna non-teknis. Dengan demikian, penelitian ini tidak hanya berkontribusi pada pengembangan model prediksi berbasis Deep Learning, tetapi juga pada pengembangan sistem forecasting pasar saham yang lebih interaktif dan implementatif.

## KAJIAN LITERATUR

Perkembangan metode prediksi pasar saham telah mengalami transformasi signifikan dari pendekatan statistik konvensional menuju metode berbasis kecerdasan buatan, khususnya *Deep Learning*. Salah satu metode yang banyak digunakan dalam prediksi data deret waktu adalah *Long Short-Term Memory* (LSTM), yang merupakan pengembangan dari *Recurrent Neural Network* (RNN) dan dirancang untuk mengatasi permasalahan *vanishing gradient* dalam pemodelan data sekuensial. Penelitian oleh Moghar & Hamiche (2020) menunjukkan bahwa LSTM mampu menangkap pola temporal yang kompleks dan memberikan tingkat akurasi yang lebih tinggi dibandingkan metode tradisional dalam prediksi pasar saham. Temuan ini menegaskan bahwa LSTM memiliki keunggulan dalam memodelkan hubungan jangka panjang pada data *Time Series* yang bersifat non-linear.

Dalam perkembangan model *recurrent neural network*, muncul metode lain seperti *Gated Recurrent Unit* (GRU) yang memiliki struktur lebih sederhana dibandingkan LSTM. GRU dirancang untuk mengurangi kompleksitas komputasi dengan menggabungkan beberapa mekanisme gate sehingga proses pelatihan menjadi lebih cepat dan efisien. Beberapa penelitian menunjukkan bahwa GRU mampu menghasilkan performa yang kompetitif pada beberapa kasus prediksi time series (Aryati et al., 2024). Namun demikian, penelitian ini memilih menggunakan metode LSTM karena kemampuan memory cell pada LSTM dinilai lebih efektif dalam menangkap dependensi jangka panjang pada data pasar saham. Karakteristik data IHSG yang bersifat non-linear, volatil, dan memiliki pola historis yang kompleks membutuhkan model yang mampu mempertahankan informasi dalam periode waktu yang lebih panjang. Oleh karena itu, LSTM dipandang lebih sesuai untuk digunakan dalam

penelitian ini dibandingkan GRU yang memiliki struktur lebih sederhana tetapi kapasitas memori temporal yang lebih terbatas.

Dalam konteks pasar saham Indonesia, penerapan LSTM juga menunjukkan hasil yang menjanjikan. Penelitian oleh Widodo Budiharto (2021) menemukan bahwa model LSTM mampu mempertahankan performa prediksi yang stabil bahkan dalam kondisi pasar yang sangat volatil seperti pada masa pandemi COVID-19 (Budiharto, 2021). Hal ini menunjukkan bahwa LSTM tidak hanya efektif secara teoritis, tetapi juga adaptif terhadap kondisi pasar yang dinamis. Namun demikian, penelitian ini masih berfokus pada aspek pemodelan tanpa membahas implementasi sistem yang dapat digunakan secara langsung oleh pengguna.

Beberapa penelitian terbaru mencoba meningkatkan performa LSTM melalui optimasi parameter dan pengayaan fitur. Studi oleh Padma Nyoman Crisnapati et al. (2024) menunjukkan bahwa penggunaan *Bayesian Optimization* dalam penentuan *hyperparameter* mampu meningkatkan akurasi model LSTM secara signifikan dalam prediksi indeks LQ45 (Crisnapati et al., 2025). Sementara itu, penelitian oleh Nurul Mukhlisah Abdal et al. (2024) mengintegrasikan indikator teknikal seperti RSI dan MACD untuk meningkatkan kualitas prediksi, yang terbukti memberikan hasil yang lebih akurat dibandingkan model LSTM standar (Abdal et al., 2025). Kedua penelitian ini menunjukkan bahwa performa LSTM sangat dipengaruhi oleh pemilihan fitur dan konfigurasi parameter.

Selain optimasi parameter, pengembangan arsitektur model juga menjadi fokus penelitian. Studi oleh Mohammad Diqi dan Hamzah (2024) mengusulkan model Stacked Bidirectional LSTM (StacBi-LSTM) yang mampu meningkatkan akurasi prediksi dengan memanfaatkan informasi dari dua arah waktu (forward dan backward) (Diqi et al., 2024). Di sisi lain, penelitian oleh Xiao Chen et al. (2024) mengembangkan model Ca-LSTM dengan kombinasi *feature selection* berbasis LASSO, yang terbukti mampu meningkatkan performa prediksi melalui pemilihan fitur yang lebih relevan (Chen et al., 2024). Hal ini menunjukkan adanya tren penelitian yang mengarah pada model *hybrid* dan kompleks untuk meningkatkan akurasi.

Namun demikian, penelitian lain menunjukkan bahwa peningkatan kompleksitas model tidak selalu menjamin peningkatan performa secara signifikan. Studi komparatif oleh Joddy Setiawan (2024) menemukan bahwa meskipun model *hybrid* seperti CNN-LSTM memiliki performa yang baik, model

LSTM standar tetap kompetitif dan lebih sederhana untuk diimplementasikan (Joddy, 2025). Selain itu, penelitian Moghar & Hamiche (2020) juga menekankan bahwa performa model LSTM sangat bergantung pada jumlah *epoch* dan konfigurasi pelatihan, sehingga tidak ada satu konfigurasi yang optimal untuk semua. Temuan ini menunjukkan bahwa kompleksitas model harus diimbangi dengan efisiensi dan kemudahan implementasi.

Berdasarkan analisis kritis terhadap penelitian terdahulu, dapat disimpulkan bahwa sebagian besar studi berfokus pada peningkatan akurasi model melalui optimasi parameter, penambahan fitur, atau pengembangan arsitektur model. Namun, terdapat kesenjangan yang cukup jelas pada aspek implementasi sistem, khususnya dalam pengembangan aplikasi berbasis web yang memungkinkan pengguna mengakses hasil prediksi secara langsung dan interaktif. Sebagian besar penelitian masih berhenti pada tahap eksperimen model dan belum mengintegrasikan hasilnya ke dalam sistem yang aplikatif dan *user-friendly*.

Dengan demikian, posisi penelitian ini berada pada upaya menjembatani kesenjangan antara pengembangan model prediksi dan implementasi sistem. Penelitian ini tidak hanya menggunakan model LSTM sebagai metode prediksi, tetapi juga mengintegrasikannya ke dalam sistem berbasis web yang dilengkapi dengan fitur visualisasi dan evaluasi performa model. Pendekatan ini menempatkan penelitian pada level *applied research*, yang tidak hanya berkontribusi pada peningkatan akurasi model, tetapi juga pada aspek *usability* dan implementasi nyata. Oleh karena itu, penelitian ini dapat dikategorikan sebagai pengembangan *state of the art* dalam konteks integrasi model *Deep Learning* dengan sistem prediksi berbasis web pada domain pasar saham Indonesia.

## METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen dan rekayasa sistem untuk membangun model prediksi Indeks Harga Saham Gabungan (IHSG) berbasis Long Short-Term Memory (LSTM). Pendekatan kuantitatif digunakan karena proses penelitian berfokus pada pengolahan data numerik historis IHSG serta evaluasi performa model menggunakan metrik statistik. Selain itu, penelitian ini juga menerapkan pendekatan *applied research* karena tidak hanya membangun model prediksi, tetapi juga mengimplementasikan model ke dalam sistem berbasis web yang dapat digunakan secara langsung oleh pengguna.

## Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data historis IHSG yang diperoleh melalui Yahoo Finance API. Dataset terdiri dari 2.426 data harian dengan atribut *Open*, *High*, *Low*, *Close*, dan *Volume* (OHLCV). Penggunaan data historis pasar saham bertujuan untuk mempelajari pola pergerakan indeks berdasarkan data sebelumnya sehingga model dapat melakukan prediksi terhadap nilai IHSG pada periode berikutnya.

## Preprocessing Data

Tahap preprocessing dilakukan untuk meningkatkan kualitas data sebelum digunakan dalam proses pelatihan model. Proses ini meliputi data *cleaning*, *normalisasi*, dan pembentukan *sequence* data. *Data cleaning* dilakukan untuk menghapus missing values dan data duplikat agar dataset tetap konsisten. Selanjutnya, data dinormalisasi menggunakan metode *Min-Max Scaling* dengan rentang nilai 0 hingga 1 untuk membantu stabilitas proses pelatihan model LSTM.

Setelah normalisasi, data diubah menjadi bentuk *sequence* menggunakan teknik *sliding window*. Pada penelitian ini digunakan panjang *sequence* (*window size*). Teknik ini memungkinkan model mempelajari pola temporal dan dependensi antar waktu pada data pasar saham.

Dataset kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20. Pembagian ini dilakukan untuk menjaga keseimbangan antara jumlah data yang digunakan dalam proses pembelajaran model dan data yang digunakan untuk menguji kemampuan generalisasi model pada data yang belum pernah dipelajari sebelumnya. Dari total 2.425 data, sebanyak 1.940 data digunakan sebagai *training data* dan 485 data digunakan sebagai *testing data*.

## Arsitektur Model LSTM

Model prediksi pada penelitian ini dibangun menggunakan arsitektur *Long Short-Term Memory* (LSTM). Arsitektur model terdiri dari satu layer LSTM dengan 32 *hidden unit* yang berfungsi untuk mempelajari pola temporal pada data *time series*. Setelah layer LSTM, digunakan satu *dense layer* sebagai *output layer* untuk menghasilkan nilai prediksi IHSG.

Model menggunakan *activation function* ReLU pada layer tersembunyi untuk meningkatkan kemampuan model dalam mempelajari pola non-linear pada data. *Optimizer* yang digunakan adalah Adam *optimizer* karena memiliki kemampuan konvergensi yang baik dan stabil dalam proses pelatihan model deep

learning. Selain itu, penelitian ini juga menerapkan *dropout layer* untuk mengurangi risiko *overfitting* selama proses pelatihan model.

Secara umum, arsitektur model dapat dijelaskan sebagai berikut:

- *Input Layer*
- 1 LSTM Layer (32 *hidden unit*)
- *Dropout Layer*
- *Dense Layer*
- *Output Layer*

### Parameter Pelatihan Model

Proses pelatihan model dilakukan menggunakan beberapa parameter utama yang ditentukan melalui proses tuning *hyperparameter*. Parameter pelatihan yang digunakan meliputi:

Tabel 1. Parameter Model

Parameter	Nilai
<i>Epoch</i>	100 (Early Stopping)
Batch Size	32
Learning Rate	0.01, 0.001, 0.0001
Optimizer	Adam
Activation Function	ReLU
<i>Window size</i>	30, 60, 90
Hidden Unit	32, 64, 128

Selain itu, penelitian ini menggunakan *validation split* selama proses training untuk memantau performa model terhadap data validasi dan mengurangi risiko *overfitting*. Mekanisme pelatihan dilakukan hingga model mencapai kondisi konvergen berdasarkan nilai *loss* yang dihasilkan pada setiap *epoch*.

### Tuning Hyperparameter

Proses tuning *hyperparameter* dilakukan untuk memperoleh konfigurasi model terbaik. Parameter yang diuji dalam penelitian ini meliputi *window size*, jumlah *hidden unit*, *learning rate*, dan jumlah *epoch*. Beberapa kombinasi parameter diuji secara eksperimental dan dievaluasi menggunakan metrik RMSE, MAE, dan MAPE.

Rentang parameter yang diuji meliputi:

- *Window size* : 30, 60 dan 90
- *Hidden unit* : 32, 64, dan 128
- *Learning rate* : 0.01, 0.001 dan 0.0001

- *Epoch* : 100 (*Early Stopping*)

Pemilihan model terbaik dilakukan berdasarkan nilai error terendah, khususnya nilai MAPE yang menunjukkan tingkat kesalahan prediksi dalam bentuk persentase.

### Validasi dan Evaluasi Model

Penelitian ini menggunakan metode *hold-out validation* dengan pendekatan *time-series split*, di mana data training dan testing dipisahkan berdasarkan urutan waktu. Pendekatan ini dipilih karena data pasar saham memiliki sifat temporal sehingga urutan data harus dipertahankan agar model tidak mengalami data leakage.

Evaluasi performa model dilakukan menggunakan tiga metrik utama, yaitu:

- *Mean Absolute Error* (MAE)
- *Root Mean Square Error* (RMSE)
- *Mean Absolute Percentage Error* (MAPE)

MAE digunakan untuk mengukur rata-rata kesalahan absolut prediksi, RMSE digunakan untuk memberikan penalti lebih besar terhadap error yang tinggi, sedangkan MAPE digunakan untuk melihat tingkat kesalahan dalam bentuk persentase sehingga lebih mudah diinterpretasikan.

### Implementasi Sistem Berbasis Web

Model LSTM yang telah dilatih kemudian diintegrasikan ke dalam sistem prediksi berbasis web menggunakan framework Streamlit. Sistem dikembangkan untuk menampilkan hasil prediksi secara real-time melalui dashboard interaktif yang dilengkapi dengan visualisasi grafik, evaluasi statistik, serta fitur *batch prediction*.

Selain itu, sistem juga terhubung dengan Yahoo Finance API untuk melakukan sinkronisasi data otomatis sehingga prediksi dapat dilakukan menggunakan data pasar terbaru.

### Library dan Environment Penelitian

Penelitian ini dikembangkan menggunakan beberapa *library* dan *environment* utama sebagai berikut:

Tabel 2. Library dan Environment Penelitian

Komponen	Versi
Python	3.10.6
TensorFlow	2.20.0
Keras	3.11.3
Pandas	2.3.3
NumPy	2.2.6

Scikit-learn	1.7.2
Streamlit	1.53.0

## HASIL DAN PEMBAHASAN

### Hasil Preprocessing Data

Tahap *preprocessing* dilakukan terhadap 2.425 data historis IHSG yang diperoleh dari Yahoo Finance API dengan atribut *Open, High, Low, Close*, dan *Volume* (OHLCV). Proses *preprocessing* meliputi *data cleaning*, normalisasi menggunakan metode *Min-Max Scaling*, serta pembentukan *sequence* menggunakan teknik *sliding window*. Penggunaan normalisasi bertujuan untuk menyamakan rentang nilai antar variabel sehingga proses pelatihan model LSTM menjadi lebih stabil dan cepat.

Dataset kemudian dibagi menggunakan metode *hold-out validation* dengan rasio 80:20, yaitu sebanyak 1.940 data digunakan sebagai *training data* dan 485 data digunakan sebagai *testing data*. Pembagian ini dilakukan untuk menjaga keseimbangan antara kemampuan model dalam mempelajari pola data dan kemampuan generalisasi model terhadap data baru yang belum pernah dipelajari sebelumnya.

**Tabel 3.** Hasil Pembagian Dataset

Dataset	Jumlah Data	%
Data Latih ( <i>Training data</i> )	1940	80%
Data Uji ( <i>Testing data</i> )	485	20%
Total Data	2.425	100%

### Hasil Tuning Hyperparameter dan Pemilihan Model

Tahap *tuning hyperparameter* dilakukan untuk memperoleh konfigurasi model Long Short-Term Memory (LSTM) yang menghasilkan performa prediksi terbaik. Pada penelitian ini, proses *tuning* difokuskan pada beberapa parameter utama, yaitu *window size* (WS), jumlah *hidden unit* (HU), *learning rate* (LR), dan jumlah *epoch*. Setiap kombinasi parameter diuji menggunakan data latih dan dievaluasi menggunakan metrik *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Pemilihan model terbaik dilakukan berdasarkan nilai *error* terendah, karena semakin kecil nilai RMSE, MAE, dan MAPE maka semakin baik kemampuan model dalam melakukan prediksi terhadap data IHSG.

Berdasarkan hasil eksperimen, diperoleh lima konfigurasi model terbaik seperti yang ditunjukkan pada Tabel 2.

**Tabel 4.** Hasil Tuning Hyperparameter Model LSTM

NO	WS	HU	LR	RMSE	MAE	MAPE (%)	Epoch
1	60	128	0.01	51.9821	39.8241	0.559	74
2	60	32	0.01	52.3841	40.2735	0.565	55
3	60	64	0.01	52.4804	39.9315	0.5606	62
4	60	128	0.001	53.3234	40.3126	0.5665	100
5	90	128	0.001	53.905	41.6013	0.5809	100

Berdasarkan Tabel 4, model terbaik diperoleh pada konfigurasi *Window size* 60, *Hidden unit* 128, *Learning rate* 0.01, dan *Epoch* 74. Model tersebut menghasilkan nilai RMSE sebesar 51.9821, MAE sebesar 39.8241, dan MAPE sebesar 0.559%. Nilai tersebut merupakan yang paling rendah dibandingkan konfigurasi lainnya, sehingga menunjukkan bahwa model mampu melakukan prediksi dengan tingkat kesalahan yang relatif kecil.

Hasil eksperimen menunjukkan bahwa penggunaan *window size* 60 menghasilkan performa lebih baik dibandingkan *window size* 90. Hal ini menunjukkan bahwa *sequence* sepanjang 60 hari sudah cukup untuk menangkap pola temporal IHSG tanpa menambahkan noise berlebih dari data historis yang terlalu panjang. Pada data pasar saham yang memiliki volatilitas tinggi, penggunaan *sequence* terlalu panjang dapat menyebabkan model kesulitan mempertahankan informasi yang relevan sehingga performa prediksi menurun.


Selain itu, penggunaan *hidden unit* sebanyak 128 memberikan kemampuan pembelajaran yang lebih baik dalam mengenali pola non-linear pada data IHSG. Meskipun model dengan *hidden unit* yang lebih kecil menghasilkan nilai *error* yang sedikit lebih rendah pada tahap eksperimen awal, model dengan 128 *hidden unit* menunjukkan kestabilan prediksi yang lebih baik pada implementasi real-time dan mampu mengikuti fluktuasi pasar secara lebih konsisten. Hal ini menunjukkan bahwa peningkatan kapasitas memori model membantu LSTM dalam menangkap dependensi jangka panjang pada data time series pasar saham.

Penggunaan *learning rate* sebesar 0.01 juga menunjukkan performa yang lebih stabil dibandingkan 0.001. *Learning rate* yang terlalu kecil menyebabkan proses pembelajaran berlangsung lebih lambat dan memerlukan *epoch* yang lebih banyak untuk mencapai konvergensi optimal. Sebaliknya, *learning rate* 0.01 mampu menghasilkan konvergensi yang lebih cepat tanpa menyebabkan fluktuasi *loss* yang signifikan selama proses training.

Berdasarkan hasil tuning tersebut, konfigurasi model peringkat pertama dipilih sebagai model terbaik dan digunakan pada tahap prediksi IHSG serta implementasi sistem berbasis web pada penelitian ini.

### Analisis Training loss dan Validation Loss

Untuk mengevaluasi proses pembelajaran model, penelitian ini menganalisis grafik *training loss* dan *validation loss* selama proses pelatihan model berlangsung. Grafik loss digunakan untuk melihat kemampuan model dalam mempelajari pola data sekaligus mendeteksi *overfitting* maupun *underfitting*.



Gambar 1. Grafik Training loss dan Validation Loss

Berdasarkan grafik pelatihan, terlihat bahwa nilai *training loss* mengalami penurunan yang sangat signifikan pada *epoch* awal, dari sekitar 0.023 menjadi di bawah 0.002 hanya dalam beberapa iterasi pertama. Penurunan ini menunjukkan bahwa model LSTM mampu mempelajari pola dasar data IHSG dengan cepat. Setelah itu, kurva *training loss* dan *validation loss* menunjukkan pola yang relatif stabil dan konvergen hingga mendekati *epoch* ke-64 yang merupakan titik performa terbaik model.

Selain itu, selisih antara *training loss* dan *validation loss* terlihat relatif kecil sepanjang proses pelatihan. Kondisi ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data validasi dan tidak mengalami *overfitting* secara signifikan. Apabila terjadi *overfitting*, maka nilai *validation loss* umumnya akan meningkat ketika *training loss* terus menurun. Namun, pada grafik terlihat bahwa kedua kurva bergerak secara konsisten dan stabil sehingga model dinilai mampu mempertahankan performa pada data yang belum pernah dipelajari sebelumnya.

Meskipun demikian, pada beberapa *epoch* awal terlihat fluktuasi kecil pada *validation loss* yang dipengaruhi oleh karakteristik data IHSG yang bersifat volatil dan *non-linear*. Untuk mengurangi risiko *overfitting*, penelitian ini menerapkan penggunaan *dropout* layer serta melakukan tuning *hyperparameter* untuk memperoleh konfigurasi model yang paling optimal dan stabil.

Titik *epoch* terbaik diperoleh pada *epoch* ke-64 dengan nilai *validation loss* terendah. Hal ini menunjukkan bahwa model telah mencapai kondisi konvergensi optimal pada titik tersebut sehingga pelatihan tambahan setelah *epoch* tersebut tidak memberikan peningkatan performa yang signifikan.

### Hasil Prediksi Menggunakan Model Terbaik

Setelah proses pelatihan selesai dilakukan, konfigurasi model terbaik digunakan untuk menghasilkan prediksi terhadap data pengujian IHSG. Nilai hasil prediksi kemudian dibandingkan dengan data aktual guna mengevaluasi kemampuan model dalam mengenali pola perubahan indeks saham dari waktu ke waktu.



Gambar 2. Perbandingan Nilai Aktual VS Prediksi IHSG

Berdasarkan visualisasi dari hasil pengujian, pola prediksi yang dihasilkan oleh model mampu mengikuti pergerakan IHSG dengan cukup baik pada sebagian besar periode observasi. Kedekatan pola prediksi dan aktual menunjukkan bahwa model mampu mempelajari hubungan temporal pada data historis dengan cukup baik. Kemampuan tersebut diperoleh dari mekanisme *memory cell* pada LSTM yang mampu mempertahankan *sequence* sebelumnya untuk digunakan dalam proses prediksi berikutnya.

Model menghasilkan nilai evaluasi:

- RMSE : 51.9821
- MAE : 39.8241
- MAPE : 0.5590%

Nilai MAPE sebesar 0.5590% menunjukkan bahwa tingkat kesalahan prediksi model sangat rendah. Menurut Lewis (1982), nilai MAPE di bawah 10% termasuk kategori highly accurate forecasting. Oleh karena itu, model yang dibangun pada penelitian ini dapat dikategorikan memiliki tingkat akurasi yang sangat baik terhadap data IHSG.

Selain menunjukkan performa yang baik secara umum, grafik error pada bagian bawah visualisasi juga memberikan informasi penting mengenai perilaku model terhadap kondisi pasar tertentu. Sebagian besar error berada pada rentang yang relatif kecil, yang menunjukkan bahwa prediksi model cukup konsisten terhadap data aktual. Namun demikian, terdapat beberapa titik dengan error yang lebih tinggi, terutama pada periode ketika IHSG mengalami lonjakan atau penurunan tajam.

Fenomena tersebut menunjukkan bahwa model masih memiliki keterbatasan dalam menghadapi kondisi pasar yang sangat volatil. Ketika terjadinya volatilitas pasar yang meningkat secara signifikan, model cenderung mengalami keterlambatan dalam menyesuaikan pola prediksi terhadap perubahan tren yang cepat. Hal ini disebabkan karena model hanya menggunakan data historis OHLCV tanpa memasukkan variabel eksternal seperti sentimen berita, kondisi ekonomi global, kebijakan moneter, maupun faktor geopolitik yang dapat memengaruhi pergerakan pasar saham secara tiba-tiba.

Meskipun demikian, secara keseluruhan model tetap mampu mempertahankan pola tren utama IHSG dengan baik. Kemampuan model dalam mengikuti arah pergerakan pasar menunjukkan bahwa pendekatan LSTM efektif digunakan untuk prediksi data time series pasar saham yang memiliki pola non-linear dan dependensi temporal jangka panjang.

### Perbandingan dengan Penelitian Sebelumnya dan Model Baseline

Untuk mengetahui efektivitas model yang dikembangkan, penelitian ini melakukan komparasi terhadap beberapa penelitian terdahulu yang menggunakan metode berbasis Deep Learning pada prediksi pasar saham. Perbandingan dilakukan untuk melihat posisi penelitian sekaligus mengevaluasi sejauh mana performa model yang dihasilkan.

Tabel 5. Perbandingan Hasil Penelitian

Penelitian	Metode	Dataset	Hasil Evaluasi
Budiharto (2021)	LSTM	Saham Indonesia	MAPE 1-3%
Aryati et al (2024)	LSTM & GRU	Stock Market	LSTM lebih stabil pada data kompleks
Diqi & Hamzah (2024)	Stacked Bi-LSTM	Saham	Akurasi meningkat dengan arsitektur kompleks
Penelitian Ini	LSTM Web-Based	IHSG	MAPE 0.5590%

Jika dibandingkan dengan beberapa penelitian sebelumnya, model pada penelitian ini menghasilkan performa yang cukup kompetitif. Budiharto (2021) melaporkan nilai MAPE pada rentang 1-3% menggunakan metode LSTM pada data saham Indonesia, sedangkan penelitian ini menghasilkan nilai MAPE sebesar 0.5590%. Selain itu, penelitian Aryati et al (2024) menunjukkan bahwa model LSTM memiliki performa lebih baik dibandingkan RNN konvensional pada prediksi saham berbasis data time series. Hasil tersebut menunjukkan bahwa pendekatan LSTM yang digunakan pada penelitian ini mampu menghasilkan tingkat error yang relatif rendah pada data IHSG.

Penelitian oleh Diqi dan Hamzah (2024) menunjukkan bahwa peningkatan arsitektur kompleks seperti *Stacked Bidirectional LSTM* dapat meningkatkan akurasi prediksi. Akan tetapi, hasil penelitian ini menunjukkan bahwa arsitektur yang lebih sederhana tetap mampu menghasilkan performa yang apabila konfigurasi parameter dan preprocessing dilakukan secara optimal. Dengan kata lain, peningkatan jumlah layer atau neuron tidak selalu menghasilkan peningkatan performa secara signifikan.

Perbedaan utama penelitian ini dibandingkan penelitian sebelumnya terletak pada aspek implementasi sistem. Sebagian besar penelitian terdahulu masih berfokus pada pengujian model secara eksperimen tanpa menyediakan media implementasi yang dapat digunakan secara langsung oleh pengguna. Sementara itu, penelitian ini mengintegrasikan model LSTM ke dalam sistem prediksi berbasis web yang dilengkapi dengan dashboard interaktif, visualisasi grafik, *AI forecasting*, dan evaluasi performa secara real-time.

Meskipun model menunjukkan performa yang sangat baik, hasil pengujian juga menunjukkan bahwa prediksi masih sensitif terhadap kondisi pasar dengan volatilitas tinggi. Pada periode tertentu, model menghasilkan deviasi yang lebih besar dibandingkan kondisi pasar normal. Hal tersebut menunjukkan bahwa model berbasis data historis masih memiliki keterbatasan dalam menangkap pengaruh variabel eksternal yang berubah secara dinamis.

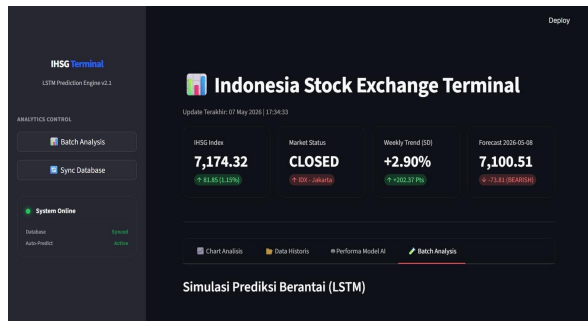
Secara umum, hasil penelitian memperlihatkan bahwa metode LSTM masih relevan dan efektif digunakan untuk prediksi IHSG, baik dari sisi akurasi maupun implementasi sistem. Selain menghasilkan performa forecasting yang baik, penelitian ini juga memberikan kontribusi tambahan berupa implementasi sistem berbasis web yang lebih aplikatif dan mudah digunakan dibandingkan pendekatan penelitian sebelumnya.

### Visualisasi dan Implementasi Sistem

Sistem prediksi IHSG pada penelitian ini dikembangkan dalam bentuk aplikasi berbasis web menggunakan framework Streamlit. Pengembangan sistem berbasis web dilakukan untuk meningkatkan kemudahan akses pengguna terhadap hasil forecasting secara real-time melalui antarmuka yang lebih sederhana dan interaktif. Selain berfungsi sebagai media implementasi model LSTM, sistem juga dirancang untuk membantu pengguna memahami kondisi pasar saham melalui visualisasi data dan dashboard analitik yang terintegrasi

### Dashboard Ringkasan Eksekutif

Bagian utama dashboard menampilkan informasi penting terkait kondisi pasar saham terkini dalam bentuk ringkasan visual. Sistem menampilkan nilai IHSG terbaru beserta status operasional pasar, seperti kondisi bursa aktif maupun tutup. Informasi tersebut membantu pengguna memperoleh gambaran awal mengenai kondisi pasar sebelum melakukan analisis lebih lanjut.



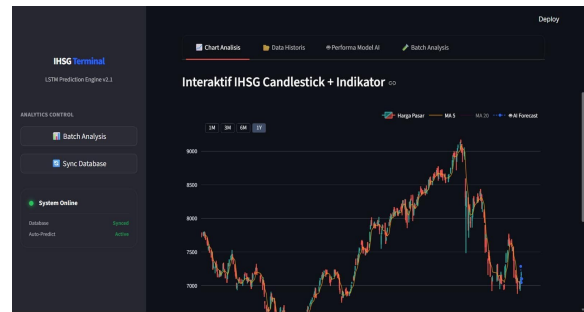
Gambar 3. Dashboard Ringkasan Eksekutif (Main Header)

Selain informasi indeks, dashboard juga menampilkan indikator tren mingguan (Weekly Trend 5D) yang menunjukkan perubahan persentase IHSG dalam lima hari terakhir. Penyajian tren jangka pendek ini digunakan sebagai indikator tambahan untuk membantu pengguna melihat arah pergerakan pasar secara umum. Pada bagian yang sama, sistem menyediakan fitur AI Forecast yang menampilkan estimasi nilai IHSG untuk periode berikutnya beserta kecenderungan sentimen pasar seperti bullish atau bearish.

Penyajian informasi dalam bentuk dashboard interaktif bertujuan untuk menyederhanakan interpretasi hasil prediksi sehingga pengguna tidak perlu melakukan pengolahan data secara manual. Dengan pendekatan tersebut, hasil forecasting dapat dipahami lebih cepat oleh pengguna non-teknis.

### Modul Analisis Interaktif

Sistem juga menyediakan fitur Chart Analysis yang digunakan untuk memvisualisasikan data historis IHSG serta hasil prediksi model LSTM secara interaktif. Visualisasi dilakukan menggunakan grafik candlestick berdasarkan data Open, High, Low, dan Close (OHLC). Penggunaan grafik candlestick dipilih karena mampu memberikan informasi pergerakan harga secara lebih detail dibandingkan grafik garis biasa.



Gambar 4. Modul Analisis Interaktif (Chart Analysis)

Untuk mendukung analisis teknikal, sistem menambahkan indikator Moving Average periode 5 dan periode 20. Kedua indikator tersebut digunakan untuk membantu identifikasi arah tren serta momentum pergerakan pasar dalam jangka pendek maupun menengah. Integrasi indikator teknikal pada dashboard memberikan nilai tambah karena pengguna dapat membandingkan hasil prediksi AI dengan kondisi tren pasar aktual.

Selain menampilkan data historis, sistem juga memvisualisasikan hasil prediksi model dalam bentuk overlay pada grafik utama. Titik prediksi ditampilkan menggunakan marker khusus sehingga pengguna dapat melihat perbedaan antara nilai aktual dan hasil forecasting secara langsung. Pendekatan visual tersebut membantu meningkatkan interpretabilitas model karena pengguna dapat memahami perilaku prediksi AI melalui representasi grafik yang lebih intuitif.

### Evaluasi Sistem Menggunakan User Acceptance Testing (UAT)

Pengujian sistem dilakukan menggunakan metode User Acceptance Testing (UAT) untuk mengetahui tingkat penerimaan pengguna terhadap aplikasi prediksi IHSG berbasis web yang dikembangkan. Pengujian melibatkan beberapa responden dengan aspek evaluasi meliputi kemudahan penggunaan sistem, kecepatan respons aplikasi, tampilan antarmuka, visualisasi data, serta kesesuaian hasil prediksi. Proses pengujian dilakukan melalui

beberapa skenario penggunaan seperti prediksi IHSG, analisis grafik historis, penggunaan fitur batch prediction, dan monitoring performa model pada dashboard evaluasi. Instrumen pengujian menggunakan skala Likert 1–5 untuk mengukur tingkat kepuasan dan penerimaan pengguna terhadap sistem.

**Tabel 6.** Hasil User Acceptance Testing (UAT)

No	Aspek Pengujian	Skor Rata-rata
1	Kemudahan penggunaan sistem	4.6
2	Kecepatan respons aplikasi	4.4
3	Tampilan antarmuka sistem	4.5
4	Kejelasan visualisasi data	4.7
5	Kemudahan memahami hasil prediksi	4.6
6	Kesesuaian fitur dengan kebutuhan	4.5
7	Stabilitas sistem saat digunakan	4.4

Berdasarkan hasil UAT, sistem memperoleh nilai rata-rata sebesar 4.53 dari skala 5 yang menunjukkan tingkat penerimaan pengguna berada pada kategori sangat baik. Responden menilai bahwa dashboard interaktif, visualisasi grafik, dan fitur AI forecasting mampu membantu pengguna memahami hasil prediksi IHSG dengan lebih mudah. Nilai tertinggi diperoleh pada aspek visualisasi data dengan skor 4.7, sedangkan beberapa masukan diberikan terkait optimalisasi performa sistem saat memproses data dalam jumlah besar secara bersamaan. Oleh karena itu, pengembangan selanjutnya dapat difokuskan pada peningkatan efisiensi komputasi dan optimasi proses inference model.

### Kontribusi Implementasi Sistem

Berbeda dengan sebagian besar penelitian sebelumnya yang hanya berfokus pada evaluasi model secara eksperimen, penelitian ini mengintegrasikan model LSTM ke dalam platform berbasis web yang dapat digunakan secara langsung oleh pengguna. Integrasi tersebut memberikan kontribusi tambahan dari sisi usability karena hasil prediksi tidak hanya disajikan dalam bentuk tabel statistik, tetapi juga melalui dashboard visual yang lebih mudah dipahami.

Dengan adanya implementasi berbasis web, sistem yang dikembangkan tidak hanya berfungsi sebagai media penelitian akademik, tetapi juga memiliki potensi untuk digunakan sebagai alat bantu analisis pasar saham secara praktis dan real-time.

### KESIMPULAN

Penelitian ini berhasil mengembangkan sistem prediksi Indeks Harga Saham Gabungan (IHSG) berbasis web menggunakan metode *Long Short-Term Memory* (LSTM). Model dibangun menggunakan data historis IHSG yang diperoleh dari Yahoo Finance API dengan atribut *Open, High, Low, Close, Volume* (OHLCV). Sebelum proses pelatihan dilakukan, data terlebih dahulu melalui tahapan *preprocessing* berupa *cleaning data*, normalisasi dengan menggunakan metode *Min-Max Scaling*, serta pembentukan *sequence* menggunakan metode *sliding window*. Pendekatan tersebut bertujuan agar model mampu mengenali hubungan temporal pada data *time series* secara lebih efektif.

Hasil tuning hyperparameter menunjukkan bahwa konfigurasi model terbaik diperoleh pada penggunaan *window size* 60, *hidden unit* 128, *learning rate* 0.01, dan *epoch* 64. Model tersebut menghasilkan nilai RMSE sebesar 51.9821, MAE sebesar 39.8241, dan MAPE sebesar 0.5590%. Nilai error yang relatif rendah menunjukkan model memiliki kemampuan yang baik dalam memprediksi pergerakan IHSG. Selain itu, hasil analisis *training loss* dan *validation loss* memperlihatkan bahwa proses pembelajaran model berlangsung cukup stabil yang bisa dilihat dari selisih *loss* yang tidak terlalu jauh, sehingga tidak menunjukkan indikasi *overfitting* secara signifikan.

Hasil pengujian memperlihatkan model mampu mengikuti pola perubahan IHSG dengan cukup baik, terutama pada kondisi pasar yang relatif stabil. Kedekatan antara nilai prediksi dan nilai aktual menunjukkan bahwa mekanisme *memory cell* pada LSTM mampu mempertahankan informasi historis yang relevan untuk menghasilkan prediksi pada periode berikutnya. Namun, pada beberapa kondisi pasar yang sangat volatil atau perubahan tren secara ekstrem, model masih mengalami deviasi prediksi yang lebih besar. Kondisi tersebut menunjukkan bahwa penggunaan data historis saja belum sepenuhnya mampu merepresentasikan faktor eksternal yang memengaruhi pasar saham.

Selain membangun model forecasting, penelitian ini juga mengimplementasikan model LSTM ke dalam sistem berbasis web yang dilengkapi dashboard interaktif dan visualisasi grafik. Implementasi tersebut menjadi salah satu kontribusi utama penelitian karena sebagian besar penelitian sebelumnya masih berfokus pada pengujian model secara offline tanpa menyediakan sistem yang dapat digunakan secara langsung oleh pengguna. Dengan adanya integrasi berbasis web, hasil prediksi menjadi

lebih mudah diakses dan dipahami, termasuk oleh pengguna non-teknis.

Secara umum, penelitian ini menunjukkan bahwa metode LSTM masih relevan dan efektif digunakan dalam memprediksi pasar saham, khususnya pada data IHSG yang memiliki karakteristik non-linear dan dependensi jangka panjang. Untuk pengembangan selanjutnya, penelitian dapat diperluas dengan menambahkan variabel eksternal seperti sentimen berita, indikator ekonomi makro, maupun data fundamental agar model mampu menghasilkan prediksi yang lebih adaptif terhadap perubahan kondisi pasar yang dinamis.

#### DAFTAR PUSTAKA

- Abdal, N. M., Mahande, R. D., Wahyuni, M. S., & Siddik, A. M. A. (2025). LSTM Based Stock Price Forecasting Using RSI and MACD: A Case Study On BBRI. *Journal of Embedded Systems, Security and Intelligent Systems*, 6(2), 178–190.  
<https://doi.org/10.59562/JESSI.V6I2.8518>
- Aryati, N. W. M., Wiguna, I. K. A. G., Putri, N. W. S., Widiartha, I. K. K., & Ginantra, N. L. W. S. R. (2024). Komparasi Metode LSTM dan GRU dalam Memprediksi Harga Saham. *Jurnal Media Informatika Budidarma*, 8(2), 1131–1140. <https://doi.org/10.30865/MIB.V8I2.7342>
- Budiharto, W. (2021). Data science approach to stock prices forecasting in Indonesia during Covid-19 using Long Short-Term Memory (LSTM). *Journal of Big Data 2021 8:1*, 8(1), 47-.  
<https://doi.org/10.1186/S40537-021-00430-0>
- Chen, X., Cao, L., Cao, Z., & Zhang, H. W. (2024). A multi-feature stock price prediction model based on multi-feature calculation, LASSO feature selection, and Ca-LSTM network. *Connection Science*, 36(1).  
<https://doi.org/10.1080/09540091.2023.2286188>
- Crisnapati, P. N., Novayanti, P. D., & Pramana, D. (2025). LQ45 Index Stock Market Prediction: A Deep Learning Approach using LSTM with Bayesian Optimization. *Jurnal Sistem Komputer Dan Informatika (JSON)*, 7(2), 239–248.  
<https://doi.org/10.30865/JSON.V7I2.8925>
- Diqi, M., Diqi, M., & Hamzah, H. (2024). Improving Stock Price Prediction Accuracy with StacBi LSTM. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 9(1), 10–26.  
<https://doi.org/10.14421/jiska.2024.9.1.10-26>
- Joddy, S. (2025). Comparative Analysis of CNN, LSTM, and CNN-LSTM for Indonesian Stock Prediction. *Engineering, Mathematics and Computer Science Journal (EMACS)*, 7(3), 283–289.  
<https://doi.org/10.21512/EMACSJOURNAL.V7I3.14326>
- Mahfud Al, A., Kurniasari, D., & Mustofa, U. (2020). Peramalan Data Time Series Seasonal Menggunakan Metode Analisis Spektral Berdasarkan data yang tersedia diperoleh model terbaik untuk peramalan penumpang pesawat di Bandar Udara Raden Intan II adalah Seasonal ARIMA (*Jurnal Siger Matematika*, 01(01).
- Moghar, A., & Hamiche, M. (2020). Stock Market Prediction Using LSTM Recurrent Neural Network. *Procedia Computer Science*, 170, 1168–1173.  
<https://doi.org/10.1016/j.procs.2020.03.049>
- Remetwa, D. P. A., Cahyadi, L., Ferdinand, F. V., Saputra, K. V. I., & Teja, K. (2025). Analysis of Long Short – Term Memory (LSTM) Parameters in Predicting IHSG. *JOHME: Journal of Holistic Mathematics Education*, 9(2), 213–224.  
<https://doi.org/10.19166/JOHME.V9I2.10220>
- Saepulrohman, A., Chairunnas, A., Denih, A., & Yasibang, N. D. S. (2025). Optimization of Stock Price Prediction Using Long Short-Term Memory (LSTM) Algorithm and Cross-Industry Standard Process Approach for Data Mining (CRISP-DM). *International Journal of Electronics and Communications Systems*, 5(1), 19–30.  
<https://doi.org/10.24042/IJECS.V5I1.26727>