(JUSS) Jurnal Sains dan Sistem Informasi ISSN 2614-8277
Vol.9 No.1, Juli 2026

# PERBANDINGAN METODE *RECURRENT NEURAL NETWORK* DAN *LONG SHORT-TERM MEMORY* DALAM PREDIKSI INDEKS HARGA SAHAM GABUNGAN

**Marsel Fajriantama Riyadi [1)], Pradita Eko Prastyo Utomo [2)] , Daniel Arsa [3)]**
[1]Fakultas Sains dan Teknologi, Universitas Jambi (penulis 1)
email: marselfajriantamariyadi@gmail.com
[2]Fakultas Sains dan Teknologi, Universitas Jambi (penulis 2)
email: pradita.eko@unja.ac.id
[3]Fakultas Sains dan Teknologi, Universitas Jambi (penulis 3)
email: danielarsa@unja.ac.id

***Abstract***

*The movement of the Indeks Harga Saham Gabungan (IHSG) exhibits high volatility influenced by macroeconomic dynamics. This study aims to compare the performance of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) architectures in predicting IHSG closing prices using a multivariate approach integrating the USD to IDR exchange rate and Bank Indonesia (BI) interest rate. Daily historical data from January 2, 2020, to December 31, 2024, were processed through normalization and sequential sliding window formation. Evaluation results indicate that the LSTM model outperformed the RNN. The LSTM model achieved a Mean Absolute Percentage Error (MAPE) of 0.8158% (99.18% accuracy), while the RNN model yielded a MAPE of 0.9314% (99.06% accuracy). Furthermore, the forecasted prices were successfully implemented into a Moving Average Crossover strategy simulation (MA-5 and MA-20) to detect Golden Cross and Death Cross momentums as automated trading signals. In conclusion, the LSTM architecture proved to be more optimal and effective in capturing financial data volatility for IHSG forecasting compared to RNN.*

***Keywords:*** *IHSG, multivariate, prediction, LSTM, RNN.*

## 1. PENDAHULUAN

Investasi di pasar modal melalui Indeks Harga Saham Gabungan (IHSG) merupakan pilar penting sekaligus tolak ukur kondisi makroekonomi di Indonesia (Rindika, 2024). Dalam perjalanannya, *investor* seringkali menghadapi tantangan volatilitas pasar yang tinggi akibat krisis global seperti pandemi COVID-19 (Rindika, 2024), serta ketidakpastian sentimen dari siklus politik dalam negeri (Suryani et al., 2021). Selain itu, pergerakan IHSG sangat rentan terhadap guncangan variabel makroekonomi eksternal. Secara teoritis, depresiasi nilai tukar Rupiah terhadap Dolar AS (USD) dan kenaikan tingkat Suku Bunga Bank Indonesia (BI Rate) memberikan dampak negatif yang menekan pergerakan indeks saham (Ramadhan & Simamora, 2022). Volatilitas yang dinamis ini menciptakan data *time series* dengan karakteristik *non-linear* yang sangat rumit dan sulit diprediksi (Suryani et al., 2021).

Kompleksitas data keuangan tersebut menyebabkan metode peramalan statistik konvensional, seperti *Autoregressive Integrated Moving Average* (ARIMA), seringkali gagal menangkap pola pasar karena bertumpu pada asumsi data yang linear (Milniadi & Adiwijaya, 2023). Sebagai solusi alternatif, *Artificial Neural Network* (ANN) menawarkan arsitektur komputasi yang sangat mumpuni dalam memproses dan menyelesaikan masalah prediksi pada dataset yang besar (Ridho et al., 2022). Salah satu algoritma turunan berbasis jaringan saraf tiruan yang paling tangguh untuk menangani data sekuensial adalah *Long Short-Term Memory* (LSTM), yang dirancang untuk menghindari masalah ketergantungan jangka panjang (Prayoga et al., 2025). Model ini memiliki mekanisme gerbang (*gating*) untuk mengatasi masalah *vanishing gradient* pada ingatan masa lalu (Khairunnisa et al., 2025).

Keandalan arsitektur ini telah dibuktikan oleh berbagai penelitian terdahulu. (Riyantoko et al., 2020) mengonfirmasi efektivitas penggunaan algoritma LSTM dalam memprediksi fluktuasi harga saham pada sektor perbankan. Hal senada juga dibuktikan oleh (Yusuf, 2021) yang berhasil mengimplementasikan LSTM untuk

memprediksi tren pergerakan nilai IHSG. Bahkan, studi komparatif membuktikan bahwa LSTM menghasilkan tingkat akurasi yang jauh lebih baik dibandingkan metode ARIMA dalam meramalkan harga saham yang sangat volatil (Milniadi & Adiwijaya, 2023). Akan tetapi, kompleksitas mekanisme sel memori pada LSTM menuntut penyesuaian parameter (*hyperparameter tuning*) yang sangat teliti, karena model rentan mengalami *overfitting* sehingga lambat merespons perubahan tren yang tiba-tiba (Sianturi et al., 2023).

Di sisi lain, karakteristik harian pasar modal yang sangat fluktuatif memunculkan asumsi akademis bahwa arsitektur dasar Recurrent Neural Network (RNN) yang lebih sederhana dan memiliki ingatan lebih pendek, berpotensi lebih lincah dan responsif merespons guncangan harian dibandingkan LSTM (Selle et al., 2022). Di samping peramalan harga, pemanfaatan hasil prediksi dalam skenario nyata juga membutuhkan instrumen pengambilan keputusan, seperti penerapan indikator analisis teknikal *Moving Average Crossover* untuk mengekstraksi sinyal transaksi jual dan beli (Doloksaribu, 2025). Oleh karena itu, penelitian ini bertujuan untuk menerapkan, menguji, sekaligus membandingkan efektivitas performa model RNN dan LSTM dalam memprediksi harga IHSG yang diintegrasikan dengan variabel makroekonomi.

## 2. METODE PENELITIAN

2.1 Tempat dan Waktu Penelitian

Peneltian ini akan dilakukan di Kota Jambi. Penelitian ini akan dilakukan dalam jangka waktu ± 3 (tiga) bulan.

2.2 Perangkat Penelitian

Perangkat keras yang digunakan dalam penelitian ini adalah komputer personal dengan spesifikasi sebagai berikut:

2.2.1 Perangkat keras (Hardware)

a. Laptop Axioo dengan spesifikasi *processor Intel® Core™* i5-1235U *CPU @* 4.4*GHz*, *RAM* 16 *GB*, dan *system type* 64-*bit operating system*.

2.2.2 Perangkat lunak (Software)

a. Sistem Operasi Windows
b. *Jupyter notebook*, Bahasa pemrograman *Python* 3.11
c. *Library*: *pandas*, *numpy*, *matplotlib*, *scikit-learn*, *TensorFlow*, *Keras*, dan *yfinance*.

2.3 Sumber Data

Dalam melakukan penelitian ini, langkah pertama yaitu pengumpulan dataset histori Indeks Harga Saham Gabungan (IHSG) beserta variabel makroekonomi pendukung. Dataset diambil dari rentang waktu 2 Januari 2020 sampai dengan 31 Desember 2024. Data pergerakan IHSG (*Open, High, Low, Close, Volume*) dan nilai tukar Dolar AS (Kurs USD) diperoleh secara sekunder melalui situs *finance.yahoo.com*, sedangkan data tingkat Suku Bunga Acuan (*BI Rate*) diperoleh dari rilis publikasi situs resmi Bank Indonesia.

Tabel 1. Definisi Operasional Variabel Penelitian

| No | Variabel | Kategori Data | Definisi Operasional |
|---|---|---|---|
| 1. | Date | Informasi Pasar | Tanggal transaksi bursa pada rentang waktu pengamatan. |
| 2. | Open Price | Informasi Pasar | Harga pembukaan IHSG pada awal sesi perdagangan. |
| 3 | High Price | Informasi Pasar | Harga level tertinggi IHSG yang dicapai pada hari tersebut. |
| 4 | Low Price | Informasi Pasar | Harga level terendah IHSG yang dicapai pada hari tersebut. |
| 5 | Close Price | Informasi Pasar | Harga penutupan terakhir IHSG pada akhir sesi perdagangan. |
| 6 | Volume | Informasi Pasar | Jumlah total lembar saham yang diperdagangkan pada |

 ISSN 2614-8277

| | | | |
|---|---|---|---|
| | | | hari tersebut. |
| 7 | Kurs (USD/IDR) | Makroekonomi | Nilai tukar mata uang Rupiah terhadap Dolar Amerika Serikat. |
| 8 | BI Rate | Makroekonomi | Tingkat suku bunga acuan yang ditetapkan oleh Bank Indonesia. |

Berdasarkan Tabel 1 di atas, variabel yang digunakan dalam penelitian ini terbagi menjadi dua kategori utama, yaitu informasi pasar dan indikator makroekonomi. Variabel informasi pasar meliputi *Open*, *High*, *Low*, *Close*, dan *Volume* yang merepresentasikan rekam jejak fluktuasi transaksi harian IHSG secara internal di bursa. Sementara itu, variabel makroekonomi yang terdiri dari Kurs (USD/IDR) dan *BI Rate* bertindak sebagai data pendukung eksternal. Penambahan variabel makroekonomi ini bertujuan untuk memberikan konteks tambahan bagi model *Machine Learning* dalam mengenali pola sentimen ekonomi yang sering kali memicu volatilitas pada IHSG.

2.4 Teknik Pengumpulan Data

Dalam proses pengumpulan data dalam penelitian ini, teknik pengumpulan data sebagai berikut:

1. Teknik *time series*

Teknik ini disusun dan dikumpulkan berdasarkan urutan waktu.

2. Studi Pustaka

Penelitian ini juga melakukan proses studi pustaka dengan membaca dan mempelajari literatur yang berkaitan dengan topik penelitian ini.

2.5 Tahapan Penelitian

Dalam melakukan penelitian ini tentunya memerlukan adanya kerangka penelitian yang jelas supaya mempermudah dalam melakukan penelitian. Maksud dari kerangka penelitian tersebut yaitu menjelaskan langkah-langkah yang akan dilakukan dalam menyelesaikan masalah dalam penelitian ini. Kerangka penelitian tersebut dapat dilihat pada gambar dibawah ini.

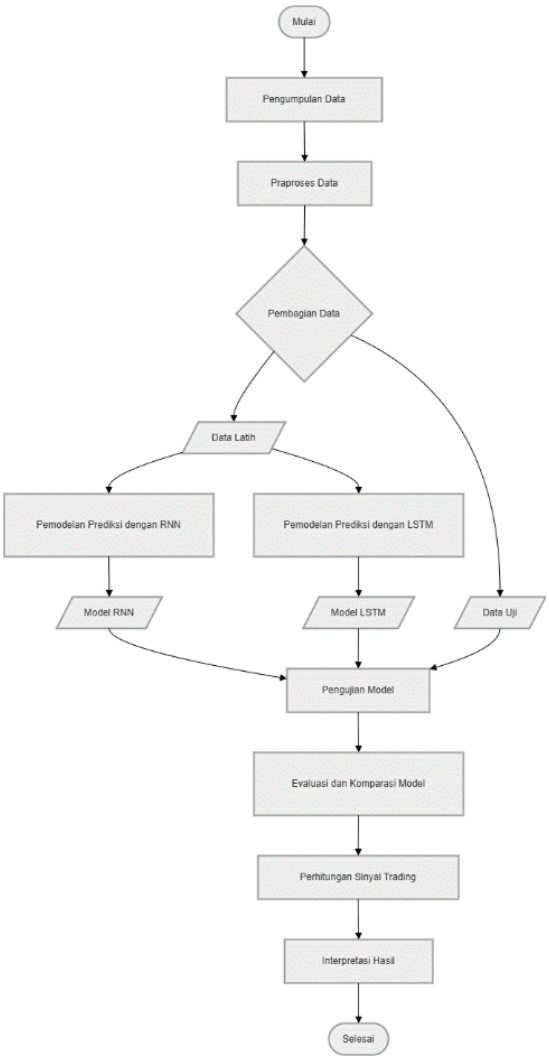


Gambar 1. Alur Penelitian

2.5.1 Pengumpulan Data

Dalam melakukan penelitian ini, diperlukan pengumpulan dataset yang berupa kumpulan data time series histori harga IHSG yang dapat dilihat pada Tabel 2.

Tabel 2. Sampel Dataset Indeks Harga Saham Gabungan

| Date | Open | High | Low | Close | Volume | Kurs | BI_Rate |
|---|---|---|---|---|---|---|---|
| 2020-01-02 | 6313.13 | 6317.01 | 6288.54 | 6288.54 | 4436000 | 13893 | 5.00 |
| 2020-01-03 | 6306.91 | 6323.47 | 6286.29 | 6323.47 | 4558000 | 13930 | 5.00 |
| 2020-01-06 | 6301.69 | 6323.00 | 6253.21 | 6257.40 | 3855000 | 13944 | 5.00 |
| 2020-01-07 | 6265.81 | 6285.55 | 6251.98 | 6279.35 | 3914000 | 13876 | 5.00 |

Tabel 2 menunjukkan cuplikan lima baris pertama dari dataset yang telah digabungkan (merge) berdasarkan tanggal transaksi sebelum memasuki tahap pra-pemrosesan.

2.5.2 *Preprocessing* Data

Tahapan pra-pemrosesan data merupakan langkah krusial untuk memastikan kualitas data sebelum dimasukkan ke dalam model RNN maupun LSTM. Data mentah sering kali

memiliki format yang tidak konsisten atau nilai yang hilang yang dapat mengganggu proses pelatihan. Pada penelitian ini, tahapan pra-pemrosesan meliputi:

a. Langkah pertama adalah memeriksa konsistensi dataset. Penelitian ini akan melakukan pengecekan terhadap *missing values* (nilai kosong) atau data duplikat. Jika ditemukan nilai *null*, data tersebut akan dihapus (*dropping*) atau diisi menggunakan teknik interpolasi linear agar tidak merusak alur pola deret waktu (*time series*).
b. Karena arsitektur algoritma RNN dan LSTM sangat sensitif terhadap skala data input, maka dilakukan normalisasi untuk menyamakan rentang nilai pada semua fitur (terutama untuk menyeimbangkan nilai volume yang jutaan dengan *BI Rate* yang hanya satuan). Metode yang digunakan adalah *Min-Max Scaler* yang mengubah data ke dalam rentang [0, 1] dengan rumus:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Dimana $x$ adalah nilai asli, $\min(x)$ adalah nilai terendah, dan $\max(x)$ adalah nilai tertinggi dalam dataset.
c. Model RNN dan LSTM di *TensorFlow/Keras* secara ketat membutuhkan input berupa urutan data 3 dimensi yaitu *(samples, time steps, features)*. Oleh karena itu, data deret waktu diubah menjadi format *supervised learning* menggunakan teknik *sliding window*. Data akan dipotong-potong berdasarkan panjang *sequence* (jendela waktu) dari beberapa hari ke belakang untuk memprediksi harga pada hari berikutnya $(t + 1)$.

2.5.3 Data Latih dan Data Uji

Data pada penelitian ini dialokasikan menjadi dua jenis, yaitu data *training* atau data pembelajaran dan data *testing* atau data uji. Pembagian data untuk model prediksi yang dibangun dibagi dengan perbandingan 90:10, dimana sebanyak 90% dari total data akan dijadikan data *training* dan 10% lainya akan dijadikan data *testing*. Kombinasi ini dipilih berdasarkan hasil uji coba serta pertimbangan setelah dilakukan percobaan terhadap beberapa perbandingan jumlah data *testing* dan *training*.

2.5.4 Pemodelan RNN dan LSTM

Pada tahap ini, dirancang dua arsitektur jaringan saraf tiruan secara terpisah, yaitu model *Recurrent Neural Network* (RNN) dasar dan *Long Short-Term Memory* (LSTM) menggunakan pustaka *TensorFlow* dan *Keras*. Kedua model tersebut dibangun menggunakan kerangka arsitektur sekuensial (*Sequential API*) dengan rancangan lapisan (*layers*) sebagai berikut:

a. Arsitektur Model RNN
   Lapisan Input (*Input Layer*) menerima masukan data dalam format struktur tiga dimensi (*batch_size*, *time_steps*, *features*) yang merepresentasikan urutan data historis multivariat (IHSG, Kurs, dan BI Rate).
   Lapisan Tersembunyi (*Hidden Layer*) menggunakan lapisan SimpleRNN untuk memproses data sekuensial guna mengekstraksi informasi berulang dari data masa lalu.
   Lapisan Output (*Dense Layer*) menggunakan lapisan *fully connected* (*Dense*) dengan 1 (satu) neuron untuk melakukan regresi dan menghasilkan satu titik nilai prediksi harga.
b. Arsitektur Model LSTM
   Lapisan Input (*Input Layer*) menerima masukan data dengan format struktur tiga dimensi yang identik dengan model RNN.
   Lapisan Tersembunyi (*Hidden Layer*) menggunakan lapisan LSTM yang dilengkapi dengan mekanisme gerbang memori internal (*forget*, *input*, *output gate*). Lapisan ini bertugas memproses data sekuensial sekaligus mengatasi kelemahan memori pada RNN dasar.
   Lapisan Output (*Dense Layer*) menggunakan 1 (satu) *neuron Dense* untuk mengeluarkan hasil prediksi kuantitatif.

Kedua model kemudian dikompilasi (*compile*) menggunakan fungsi kerugian (loss function) berupa *Mean Squared Error* (MSE) dan algoritma optimasi *Adaptive Moment Estimation* (Adam) agar evaluasi komparasi kinerja dapat diukur secara adil.

2.5.5 Penentuan Sinyal Jual/Beli

Mengingat karakteristik IHSG yang fluktuatif, penelitian ini menerapkan strategi perdagangan jangka pendek (*short-term trading*) untuk menangkap momentum keuntungan dari pergerakan harga harian hasil prediksi dari model terbaik. Strategi ini

menggunakan metode *Moving Average Crossover* dengan periode yang lebih sensitif, yaitu *Fast Moving Average* (MA-5) dan *Slow Moving Average* (MA-20).

a. Perhitungan Moving Average
Nilai rata-rata bergerak dihitung menggunakan data harga penutupan (*Close Price*) hasil prediksi (P). Rumus *Simple Moving Average* (SMA) didefinisikan sebagai:

$$SMA_n(t) = \frac{1}{n}\sum_{i=0}^{n-1} P_{t-i} \quad (2)$$

Pada perhitungan formulasi tersebut, variabel $SMA_n(t)$ merepresentasikan nilai rata-rata bergerak pada hari ke-$t$. Variabel $n$ menunjukkan periode waktu pengamatan yang digunakan, di mana strategi pada penelitian ini menetapkan nilai $n = 5$ untuk mewakili satu minggu hari kerja bursa, serta $n = 20$ untuk mewakili satu bulan hari kerja bursa. Sementara itu, variabel $P_{t-i}$ merupakan harga prediksi yang dihasilkan oleh model terbaik pada waktu $t - i$.

b. Algoritma Keputusan Jual/Beli
Sinyal transaksi ditentukan berdasarkan persilangan garis tren jangka pendek (MA-5) terhadap tren menengah (MA-20):
Sinyal Beli (*Golden Cross*): Sinyal beli dipicu ketika garis rata-rata 5 hari memotong ke atas garis rata-rata 20 hari. Ini mengindikasikan momentum kenaikan harga jangka pendek sedang terbentuk.

$$Kondisi: SMA_5(t) > SMA_{20}(t)$$
$$\text{DAN}$$
$$SMA_5(t-1) \leq SMA_{20}(t-1) \quad (3)$$

Maka keputusan = Beli
Sinyal Jual (*Death Cross*): Sinyal jual dipicu ketika garis rata-rata 5 hari memotong ke bawah garis rata-rata 20 hari. Ini mengindikasikan tren harga jangka pendek mulai melemah atau turun.

$$Kondisi: SMA_5(t) < SMA_{20}(t)$$
$$\text{DAN}$$
$$SMA_5(t-1) \geq SMA_{20}(t-1) \quad (4)$$

Maka Keputusan = Jual
Sinyal Tahan (*Hold*): Jika tidak terjadi perpotongan antar garis, maka tidak ada aksi perdagangan yang dilakukan.
Maka Keputusan = Tahan

2.5.6 Evaluasi

Kinerja dari model yang telah dibangun selanjutnya dievaluasi melalui tiga metrik pengukuran, yaitu *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). RMSE merupakan metode untuk mengevaluasi teknik peramalan dengan mengukur tingkat akurasinya (Hudzaifah & Rismayadi, 2021). Perhitungan RMSE menggunakan persamaan matematis berikut:

$$RMSE = \sqrt{\frac{\Sigma_{t=1}^{n}(A_t - F_t)}{n}} \quad (5)$$

Pada persamaan tersebut, variabel $A_t$ merepresentasikan nilai data aktual, $F_t$ adalah nilai hasil peramalan, dan $n$ menunjukkan banyak data. Selanjutnya, evaluasi dilanjutkan dengan menghitung nilai MAE untuk mengetahui akurasi prediksi dengan melihat seberapa besar rata-rata kesalahan absolut dari model peramalan. Persamaan MAE dirumuskan sebagai berikut:

$$MAE = \frac{1}{n}\sum_{t=1}^{n} |x_t - f_t| \quad (6)$$

Pada persamaan MAE, variabel $x_t$ mewakili nilai aktual pada waktu $t$, variabel $f_t$ mewakili nilai prediksi pada waktu $t$, dan $n$ adalah jumlah data keseluruhan. Metrik terakhir yang digunakan adalah MAPE, yakni rata-rata dari diferensiasi antara hasil sebenarnya dan nilai peramalan yang dinyatakan melalui persentase nilai aktual (Wiranda & Sadikin, 2019). Rumus perhitungan MAPE adalah sebagai berikut:

$$MAPE = \frac{1}{n}\sum_{t=1}^{n} \left|\frac{A_t - F_t}{A_t}\right| \times 100\% \quad (7)$$

Pada rumusan MAPE tersebut, variabel $A_t$ merupakan data aktual pada waktu ke-$t$, $F_t$ merepresentasikan nilai hasil peramalan pada waktu ke-$t$, dan $n$ adalah jumlah (banyaknya) data observasi yang diuji.

2.6 Metode Analisis Data

Pada penelitian ini digunakan model peramalan dari teknik statistik dan teknik *Deep Learning* yakni model RNN (*Recurrent Neural Network*) dan LSTM (*Long Short Term Memory*). Tahapan analisis yang akan dilakukan peneliti untuk analisis menggunakan RNN dan LSTM. Tahapan untuk analisi melalui model peramalan RNN dan LSTM yaitu:

1. Pengumpulan Data historis Indeks Harga Saham Gabungan (IHSG) beserta variabel makroekonomi pendukung (Kurs USD dan BI *Rate*) sesuai dengan rentang waktu penelitian yang telah ditetapkan.
2. Pra-pemrosesan data untuk pembersihan dan persiapan data agar siap diolah oleh komputer. Tahap ini meliputi penanganan data yang hilang (*missing value*), penyelarasan format tanggal, normalisasi rentang nilai data menggunakan metode skala tertentu, serta pembagian rasio dataset menjadi data latih (*training set*) dan data uji (*testing set*).
3. Pembuatan Arsitektur Model *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) menggunakan pustaka (*library*) *TensorFlow* dan *Keras* pada bahasa pemrograman *Python*.
4. Pelatihan kedua model secara paralel menggunakan data latih yang telah dipersiapkan agar sistem mampu mengenali pola deret waktu. Untuk memastikan perbandingan kinerja yang adil (*fair comparison*), model RNN dan LSTM akan dieksekusi menggunakan *hiperparameter* standar yang seragam, meliputi konfigurasi *learning rate*, jumlah *epoch*, ukuran *batch*, dan penggunaan fungsi optimasi *Adam*.
5. Validasi dan Prediksi model yang telah dilatih menggunakan data uji (*testing set*). Tahap ini bertujuan untuk melihat sejauh mana model RNN maupun LSTM dapat memprediksi pergerakan angka IHSG yang sebenarnya.
6. Evaluasi Performa dan membandingkan tingkat akurasi serta kesalahan prediksi dari kedua model secara kuantitatif. Metrik pengukuran yang digunakan meliputi RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*), dan MAPE (*Mean Absolute Percentage Error*).
7. Simulasi Sinyal Perdagangan. Menerapkan strategi perdagangan algoritmis jangka pendek (*short-term trading*) pada hasil prediksi yang paling optimal menggunakan metode *Moving Average Crossover*. Tahap ini mencakup perhitungan garis rata-rata pergerakan (MA) periode cepat dan lambat, serta penentuan eksekusi sinyal (Beli atau Jual) berdasarkan deteksi pola *Golden Cross* dan *Death Cross*.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Pra-pemrosesan dan Pembagian Data

Sebelum model dilatih, tahapan pra-pemrosesan dilakukan terhadap dataset historis IHSG dan variabel makroekonomi (Kurs USD dan BI Rate) periode 2020 hingga 2024. Setelah dipastikan tidak ada nilai yang kosong (*missing value*), seluruh fitur data dinormalisasi menggunakan *Min-Max Scaler* agar memiliki skala yang seragam, yaitu pada interval [0,1]. Data yang telah dinormalisasi tersebut kemudian dipartisi menjadi dua bagian, yakni 90% dialokasikan sebagai data latih (*training set*) untuk proses pembelajaran model, dan 10% dialokasikan sebagai data uji (*testing set*) untuk memvalidasi kinerja peramalan. Data kemudian dibentuk ke dalam urutan *time series* 3 dimensi menggunakan teknik *sliding window*.

### 3.2 Hasil Evaluasi dan Komparasi Model

Pemodelan *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) dieksekusi secara paralel menggunakan parameter yang seragam, yaitu 64 neuron pada *hidden layer*, fungsi optimasi Adam, dan iterasi sebanyak 100 *epoch*. Setelah proses pelatihan selesai, data uji digunakan untuk mengukur tingkat kesalahan dari masing-masing model. Hasil evaluasi berdasarkan metrik RMSE, MAE, dan MAPE dapat dilihat pada Tabel 3.

Tabel 3. Hasil Evaluasi Performa Model RNN dan LSTM

| No | Model Deep Learning | Nilai MAPE (%) | Akurasi Prediksi (%) | Keterangan |
|---|---|---|---|---|
| 1 | Recurrent Neural Network (RNN) | 0.9314 | 99.0686 | Sangat Baik |
| 2 | Long Short-Term Memory (LSTM) | 0.8158 | 99.1842 | Sangat Baik |

Berdasarkan Tabel 3, kedua arsitektur menunjukkan kemampuan yang sangat baik dalam mengenali pola data finansial. Namun, model LSTM memberikan hasil yang lebih

 ISSN 2614-8277

superior dibandingkan model RNN. Model LSTM berhasil menekan nilai *Mean Absolute Percentage Error* (MAPE) hingga mencapai 0.8158%, yang berarti tingkat akurasi peramalannya adalah sebesar 99.18%. Sementara itu, model RNN menghasilkan nilai MAPE sebesar 0.9314% (akurasi 99.06%). Keunggulan ini mengonfirmasi bahwa mekanisme gerbang pengendali (*forget, input, output gate*) pada memori internal LSTM sangat efektif dalam mempertahankan informasi tren masa lalu yang relevan sekaligus menyaring derau (*noise*) pada data pasar modal.

3.3 Visualisasi Hasil Prediksi IHSG

Berdasarkan hasil komparasi, model LSTM ditetapkan sebagai model terbaik. Hasil prediksi harga penutupan IHSG dari model LSTM kemudian divisualisasikan dan dibandingkan dengan pergerakan harga penutupan aktual (sebenarnya) di bursa.

Gambar 2. Grafik Perbandingan Harga Prediksi LSTM terhadap Harga Aktual IHSG

Pada Gambar 2, dapat dilihat bahwa garis pergerakan harga prediksi menempel dengan sangat rapat pada garis harga aktual. Model LSTM terbukti mampu merespons volatilitas pasar, baik saat tren sedang mengalami kenaikan tajam (*bullish*) maupun penurunan (*bearish*).

3.4 Ekstraksi Sinyal Trading

Sebagai bentuk penerapan praktis, hasil prediksi harga IHSG diintegrasikan dengan algoritma analisis teknikal *Moving Average Crossover* untuk menghasilkan sinyal perdagangan otomatis. Sistem membandingkan pergerakan harga rata-rata jangka pendek selama 5 hari (MA-5) dan pergerakan jangka menengah selama 20 hari (MA-20).

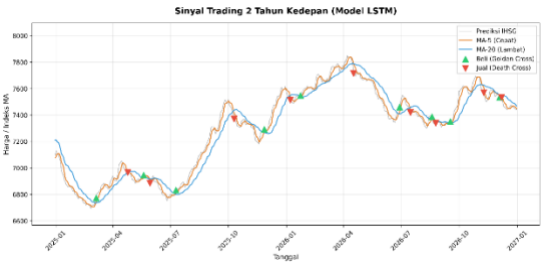


Gambar 3. Hasil Ekstraksi Sinyal Trading Golden Cross dan Death Cross

Berdasarkan Gambar 3, algoritma berhasil mengidentifikasi titik-titik momentum kritis. Ketika garis MA-5 memotong garis MA-20 ke arah atas, sistem mengonfirmasi adanya tren positif dan mengeksekusi Sinyal Beli (*Golden Cross*). Sebaliknya, ketika garis MA-5 memotong tajam ke bawah garis MA-20, sistem mendeteksi pelemahan tren dan merekomendasikan Sinyal Jual (*Death Cross*). Simulasi ini membuktikan bahwa keluaran prediksi algoritma *Deep Learning* dapat dikonversi menjadi instrumen pengambilan keputusan investasi yang valid.

## 4. KESIMPULAN

Berdasarkan hasil penelitian dan pengujian yang telah dilakukan, penerapan algoritma *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) untuk memprediksi Indeks Harga Saham Gabungan (IHSG) berhasil dibangun dengan konfigurasi paling optimal yaitu menggunakan 64 neuron, iterasi sebanyak 100 *epoch*, dan *optimizer* Adam. Hasil perbandingan menunjukkan bahwa model LSTM memiliki performa yang lebih unggul dibandingkan RNN. Model LSTM mampu menekan persentase tingkat kesalahan (*Mean Absolute Percentage Error* / MAPE) hingga angka 0.8158% (tingkat akurasi 99.18%), sedangkan model RNN menghasilkan nilai MAPE sebesar 0.9314% (tingkat akurasi 99.06%). Keunggulan ini membuktikan bahwa penambahan *memory cell* dan mekanisme gerbang pengendali pada LSTM sangat efektif untuk menangkap volatilitas data finansial. Selain berhasil melakukan peramalan harga untuk periode 2025–2026, model terbaik yang dibangun juga sukses dimanfaatkan untuk memberikan rekomendasi sinyal *trading* (*Golden Cross* dan *Death Cross*) menggunakan metode perpotongan *Moving Average* (MA-5 dan MA-20).

## 5. REFERENSI

Doloksaribu, A. M. S. G. (2025). *Analisis Tren dan Volatilitas Saham BBRI Menggunakan Moving Average dan Standar Deviasi*. *6*(4), 389–394. https://doi.org/10.62527/jitsi.

Hudzaifah, M., & Rismayadi, A. A. (2021). *Peramalan Arus Lalu Lintas Berdasarkan Waktu Tempuh dan Cuaca Menggunakan Metode Time Series Decomposition*. *3*(2), 207–215.

Khairunnisa, A., Muflikhah, L., & Setiawan, B. D. (2025). Pemodelan Prediktif Harga Saham Menggunakan Simple Moving Average Dengan Metode Long Short-Term Memory. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, *9*(3), 2548–2964. http://j-ptiik.ub.ac.id

Milniadi, A. D., & Adiwijaya, N. O. (2023). Analisis Perbandingan Model Arima Dan Lstm Dalam Peramalan Harga Penutupan Saham ( Studi Kasus : 6. *Sibatik Journal*, *2*(6).

Prayoga, K., Alam, S., & Kurniawan, I. (2025). *Implementasi Long Short-Term Memory (LSTM) untuk Forecasting Harga Cryptocurrency*. *9*(5), 8336–8342.

Ramadhan, D. F., & Simamora, S. C. (2022). *Pengaruh Nilai Tukar (Kurs) dan Suku Bunga (BI Rate) terhadap Indeks Harga Saham Gabungan (IHSG) di Masa Pandemi*. *2*(2), 142–153.

Ridho, I. I., Mahalisa, G., Sari, D. R., & Fikri, I. (2022). Metode Neural Network Untuk Penentuan Akurasi Prediksi Harga Rumah. *Technologia : Jurnal Ilmiah*, *13*(1), 56. https://doi.org/10.31602/tji.v13i1.6252

Rindika, S. M. (2024). the Impacts of Macroeconomic Variables on the Movement of Composite Stock Price Index (Cspi) During Covid-19 Pandemic in Indonesia. *Berkala Akuntansi Dan Keuangan Indonesia*, *9*(2), 220–240. https://doi.org/10.20473/baki.v9i2.58835

Riyantoko, P. A., Fahruddin, T. M., Hindrayani, K. M., & Safitri, E. M. (2020). Analisis Prediksi Harga Saham Sektor Perbankan Menggunakan Algoritma Long-Short Terms Memory (Lstm). *In Seminar Nasional Informatika (SEMNASIF)*, *1*(1), 427–435.

Selle, N., Yudistira, N., & Dewi, C. (2022). Perbandingan Prediksi Penggunaan Listrik dengan Menggunakan Metode Long Short Term Memory (LSTM) dan Recurrent Neural Network (RNN). *Jurnal Teknologi Informasi Dan Ilmu Komputer*, *9*(1), 155. https://doi.org/10.25126/jtiik.2022915585

Suryani, F., Purwohedi, U., & Mardi. (2021). Analisis Perbandingan Indeks Harga Saham Sebelum dan Sesudah Penetapan Covid-19 Sebagai Pandemi. *Jurnal Akuntansi, Perpajakan Dan Auditing*, *2*(3), 751–766. https://doi.org/10.21009/japa.0203.15

Wiranda, L., & Sadikin, M. (2019). Penerapan Long Short Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk Pt. Metiska Farma. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, *8*(3), 184–196.

Yusuf, A. (2021). *Prediksi Indeks Harga Saham Gabungan ( IHSG ) Menggunakan Long Short-Term Memory*. *15*, 124–132.