

PREDIKSI HARGA SAHAM INDOFOOD MENGUNAKAN LONG SHORT-TERM MEMORY

Agung Fajar Risnandar, Fidi Supriadi, Dani Indra Junaedi

Informatika, Universitas Sebelas April

Jl. Angkrek Situ No.19 Sumedang, Jawa Barat 45323

a22100009@mhs.stmik-sumedang.ac.id

ABSTRAK

Jumlah investor saham di Indonesia terus meningkat, sehingga diperlukan model prediksi harga saham yang akurat untuk membantu pengambilan keputusan investasi. Pergerakan harga saham yang volatil menimbulkan risiko tinggi bagi investor, sehingga pendekatan berbasis data menjadi solusi yang relevan. Penelitian ini bertujuan untuk memprediksi harga saham Indofood Sukses Makmur (INDF) menggunakan model *Long Short-Term Memory* (LSTM), yang dirancang untuk menangani data deret waktu dengan ketergantungan jangka panjang. Data yang digunakan mencakup harga saham harian dari 2014 hingga 2024, serta indikator teknikal seperti *Exponential Moving Average* (EMA), *Relative Strength Index* (RSI), dan *Moving Average Convergence Divergence* (MACD). Dataset dibagi menjadi *train* (70%), *validation* (15%), dan *test* (15%), lalu model dilatih selama 250 epoch. Evaluasi menggunakan MSE, RMSE, MAE, dan R^2 menunjukkan bahwa model memiliki performa yang baik dengan nilai kesalahan rendah (MSE: 0,0010, RMSE: 0,0316, MAE: 0,0244) serta akurasi tinggi (R^2 : 0,9232). Analisis fitur menunjukkan bahwa harga penutupan ("Close") memiliki pengaruh terbesar terhadap prediksi, diikuti oleh "High" dan EMA_4. Model ini diharapkan dapat menjadi alat bantu bagi investor dalam menganalisis tren pasar saham secara lebih efektif.

Kata kunci : Peramalan harga, time series, Saham, Indofood, Machine Learning, Long Short-Term Memory (LSTM)

1. PENDAHULUAN

Sepanjang tahun 2024, jumlah investor saham, menurut data BEI, telah melampaui 6 juta *Single Investor Identification* (SID) per Rabu (25/9), dengan pertumbuhan lebih dari 744 ribu investor yang diklaim dari sosialisasi investasi oleh *Self-Regulatory Organization* (SRO) dengan dukungan Otoritas Jasa Keuangan (OJK) dari Januari hingga Agustus 2024, Bursa Efek Indonesia (BEI) telah melakukan lebih dari 17.083 kegiatan edukasi pasar modal [1].

Memprediksi pergerakan harga saham sulit karena ketidakpastian dan volatilitas yang tinggi. Investor secara langsung dihadapkan pada risiko setiap kali mereka membuat keputusan ekonomi [2].

Investor bersedia menerima risiko dalam kondisi ketidakpastian yang disebut toleransi risiko [3]. Risiko memiliki efek yang signifikan pada keputusan investasi [4].

Risiko yang dimaksud adalah risiko perbedaan selisih nilai harga saham, besarnya deviasi antara tingkat return yang diharapkan dengan tingkat return actual [5].

Risiko pasar memiliki dampak yang mempengaruhi seluruh nilai saham [6].

Ada serangkaian analisis yang dilakukan oleh investor sebelum memutuskan untuk berinvestasi, dan analisis ini berfungsi untuk mengantisipasi risiko [7].

Teknikal analisis berfokus pada perkiraan harga aset masa depan menggunakan data historis[8].

Hal ini membuat data historis relevan untuk memprediksi harga di masa depan, yang menghasilkan tingkat prediktabilitas tertentu [8].

Peramalan menggunakan teknikal analisis berarti menggunakan indikator teknikal yang diperoleh dari data deret waktu atau data historis suatu saham. Sebagian trader menggunakan indikator teknikal sebagai alat utama, dan yang lain hanya menggunakannya sebagai alat konfirmasi [9].

Praktisi telah lama menggunakan indikator teknis untuk memprediksi *return* saham [8].

Dengan kemajuan dalam Kecerdasan Buatan, ketersediaan data yang melimpah, dan peningkatan kemampuan komputasi, menciptakan model kuat yang mampu memprediksi pergerakan pasar saham secara akurat sekarang dapat dilakukan [10].

Model LSTM telah digunakan sebagai model high tech [11].

LSTM memiliki kemampuan yang kuat untuk memprediksi data deret waktu dengan akurasi tinggi [2].

Namun untuk memprediksi harga saham model seperti *Random Forest* dan *XGBoost* dapat juga digunakan. *Random Forest* baik dalam perkiraan *internal* dari kesalahan generalisasi sehingga tidak memerlukan *cross-validation* [12].

XGBoost menggunakan metode *decision trees* sebagai *base learner*, di mana setiap pohon dibangun secara iteratif dengan menambahkan satu pohon pada satu waktu ke dalam model [13].

Pada penelitian yang dilakukan oleh Aqbar berjudul *Performance Analysis of LSTM and XGBoost Models Optimization in Forecasting Crude Palm Oil (CPO) Production at Palm Oil Mill (POM)* disimpulkan bahwa model LSTM memiliki RMSE sebesar 21,04, MAPE sebesar 0,063, dan tingkat

akurasi sebesar 93,7%, sedangkan model *XGBoost* memiliki RMSE sebesar 22,17, MAPE sebesar 0,072, dan tingkat akurasi sebesar 92,8%. Sehingga didapatkan kesimpulan bahwa model LSTM lebih unggul dalam memprediksi data produksi minyak CPO [14]. Penelitian yang dilakukan oleh Ula berjudul *Comparing Long Short-Term Memory and Random Forest Accuracy for Bitcoin Price Forecasting* menyimpulkan bahwa model LSTM secara konsisten mengungguli model *Random Forest* dalam hal prediksi harga. LSTM menunjukkan akurasi superior dengan tingkat akurasi 99,8%, yang tercermin dari rendahnya *Mean Absolute Percentage Error* (MAPE) sebesar 0,0204. Sebaliknya, model *Random Forest* hanya mencapai akurasi sebesar 90,1% dengan MAPE sebesar 0,9999 [15].

Oleh karena itu, LSTM banyak digunakan dalam penelitian prediksi harga saham [12].

Data saham umumnya berbentuk deret waktu, sehingga metode Long Short-Term Memory (LSTM) cocok dan tepat dalam penelitian ini untuk memprediksi harga saham. Penelitian ini bertujuan untuk memprediksi harga saham Indofood Sukses Makmur dengan menggunakan LSTM.

2. TINJAUAN PUSTAKA

2.1. Saham

Indonesia *Stock Exchange* (IDX) mendefinisikan saham sebagai tanda penyertaan modal seseorang atau pihak (badan usaha) dalam suatu perusahaan atau perseroan terbatas. Pemegang saham dapat mengklaim pendapatan dan aset perusahaan dengan memasukkan modal. Pemegang saham memiliki hak untuk menghadiri Rapat Umum Pemegang Saham (RUPS) [1].


Harga saham suatu perusahaan selalu mengalami pergerakan naik dan turun dari waktu ke waktu, pemegang saham akan menerima imbal balik dari saham tersebut oleh karena itu, harga saham menentukan kekayaan pemegang saham [7].

Saham yang akan diteliti dalam jurnal ini tercatat di Bursa Indonesia dan masuk dalam indeks LQ45 yaitu Indofood Sukses Makmur dengan kode saham INDF. Perusahaan ini didirikan pada tanggal 14 Agustus 1990, dengan nama PT Panganjaya Intikusuma, kemudian pada tanggal 5 Februari 1994, berganti nama menjadi Indofood Sukses Makmur. Data saham INDF diambil menggunakan Yahoo Finance API (INDF. JK).

2.2. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah jenis jaringan saraf yang dirancang khusus untuk mengatasi masalah ketergantungan jangka panjang yang sering muncul dalam pemrosesan urutan data, seperti deret waktu. Salah satu keunggulan utama LSTM adalah kemampuannya untuk mengatasi masalah *gradient exploding* dan *gradient vanishing* yang sering terjadi dalam pembelajaran ketergantungan jangka panjang, bahkan ketika jeda waktu antar titik data sangat lama.

Hal ini dimungkinkan oleh *Constant Error Carousel* (CEC) yang menjaga sinyal kesalahan tetap stabil di sel unit LSTM [12].



Gambar 1.. Arsitektur LSTM [12]

Gambar 1 merupakan algoritma LSTM (Long Short-Term Memory) yang dapat dijelaskan menggunakan beberapa komponen utama untuk memproses urutan data [12].

Proses dimulai dengan *input block*, yang menggabungkan input $x^{(t)}$ saat ini dan output dari iterasi sebelumnya $y^{(t-1)}$, dihitung dengan persamaan:

$$Z^{(t)} = g(W_Z X^{(t)} + R_Z Y^{(t-1)} + b_Z) \quad (1)$$

Selanjutnya, *input gate* memperbarui penggabungan input gate $x^{(t)}$, $y^{(t-1)}$, dan nilai sel $c^{(t-1)}$ Dari iterasi sebelumnya:

$$i^{(t)} = \sigma(W_i x^{(t)} + R_i y^{(t-1)} + p_i \odot c^{(t-1)} + b_i) \quad (2)$$

Kemudian, *forget gate* menentukan informasi yang perlu dihapus dari sel sebelumnya $c^{(t-1)}$, Dihitung dengan:

$$f^{(t)} = \sigma(W_f x^{(t)} + R_f y^{(t-1)} + p_f \odot c^{(t-1)} + b_f) \quad (3)$$

Nilai sel dihitung dengan menggabungkan nilai *input block* $z^{(t)}$, *input gate* $i^{(t)}$, dan *forget gate* $f^{(t)}$, serta nilai sel sebelumnya:

$$c^{(t)} = z^{(t)} \odot i^{(t)} + c^{(t-1)} \odot f^{(t)} \quad (4)$$

Selanjutnya, *output gate* diperbarui dengan menggabungkan $x^{(t)}$, $y^{(t-1)}$ dan $c^{(t-1)}$:

$$o^{(t)} = \sigma(W_o x^{(t)} + R_o y^{(t-1)} + p_o \odot c^{(t)} + b_o) \quad (5)$$

Akhirnya, *output block* dihitung dengan menggabungkan nilai sel $c^{(t)}$ dan *output gate* $o^{(t)}$:

$$y^{(t)} = g(c^{(t-1)}) \odot o^{(t)} \quad (6)$$

Dalam persamaan di atas, σ adalah fungsi aktivasi *sigmoid*. Pada saat yang sama, g dan h adalah fungsi aktivasi tangen hiperbolik (*tanh*) yang digunakan untuk nilai *input* dan *output*, proses ini memungkinkan LSTM untuk mengelola informasi jangka panjang dengan mengontrol aliran data melalui gate [12].

2.3. Indikator Teknikal

Teknikal analisis diperkenalkan untuk meminimalkan risiko dan memperkirakan arah tren saham. Banyak trader top dan manajer keuangan sangat bergantung pada teknikal analisis.

2.3.1. Exponential Moving Average (EMA)

EMA merupakan pengembangan lebih lanjut dari varian *Moving Averages* sebelumnya (SMA dan WMA), EMA membobotkan perhitungan yang

semakin berat untuk hari yang semakin akhir. Rumus untuk menghitung EMA adalah:

$$EMA_t = \left(\frac{2}{N+12}\right) \times (P_t - EMA_{t-1}) + EMA_{t-1} \quad (7)$$

EMA_t = Nilai EMA pada waktu t

P_t = harga penutupan pada waktu t

N = periode (misalnya, 14 hari)

EMA_{t-1} = Nilai EMA pada waktu sebelumnya

2.3.2. Moving Average Convergence Divergence (MACD)

MACD merubah *Moving Averages* yang berkarakteristik *Lagging Indicator*, menjadi bentuk momentum osilator (*Leading Indicator*). Rumus untuk menghitung MACD adalah:

$$MACD = EMA_{12} - EMA_{26} \quad (8)$$

EMA_{12} = *Exponential Moving Average* periode 12

EMA_{26} = *Exponential Moving Average* periode 26

Selanjutnya, untuk menghitung *Exponential Moving Average* periode yang merupakan EMA 9 dari MACD:

$$SignalLine = EMA_{12}(MACD) \quad (9)$$

2.3.3. Relative Strength Index (RSI)

RSI merupakan osilator (*Leading Indicator*) betasan level terendah dan level tertinggi, berskala 0 sampai dengan 100. Rumus untuk menghitung RSI adalah:

$$RSI = 100 - \left(\frac{100}{1+RS100}\right) \quad (10)$$

RSI = Relative Strength, dihitung dengan membagi rata-rata perubahan harga ke atas (kenaikan harga) dengan rata-rata perubahan harga ke bawah (penurunan harga) selama periode tertentu (misalnya, 14 hari).

2.3.4. Close Lag

Close Lag mengacu pada selisih antara harga penutupan saat ini dan harga periode sebelumnya. Rumusnya adalah:

$$Close\ Lag = Close_t - Close_{t-1} \quad (11)$$

$Close_t$ = harga penutupan pada waktu t

$Close_{t-1}$ = harga penutupan pada periode sebelumnya.

2.3.5. Signal Line

Seperti yang disebutkan di atas, *Signal Line* dalam konteks MACD adalah 9 EMA MACD:

$$SignalLine = EMA_9(MACD) \quad (12)$$

2.4. Skor Metrik

Dalam mengevaluasi model prediksi, terutama model regresi, beberapa metrik yang umum digunakan mengukur sejauh mana prediksi model menyimpang dari nilai aktual [16].

Empat metrik kesalahan yang paling banyak digunakan adalah *Mean Squared Error* (MSE) [17], *Root Mean Squared Error* (RMSE) [18], *Mean Absolute Error* (MAE) [19], dan *Coefficient of Determination* (R^2). Masing-masing dari keempat metrik ini memiliki karakteristik yang berbeda saat menilai performa model.

2.4.1. Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah rata-rata kuadrat dari perbedaan antara nilai prediksi dan aktual. MSE memberikan penalti kesalahan yang lebih signifikan karena perbedaannya dikuadratkan. Hal ini membuat MSE sangat sensitif terhadap outlier (data yang jauh dari nilai prediksi atau aktual). Rumus MSE:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (13)$$

y_i = nilai aktual pada datai

$\hat{y}_i$ = nilai prediksi pada datai

n = jumlah data

2.4.2. Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) adalah akar kuadrat MSE, yang juga mengukur perbedaan rata-rata antara nilai prediksi dan aktual. Dengan menghitung akar kuadrat MSE, RMSE mengembalikan metrik ke skala yang sama dengan data asli, sehingga lebih mudah untuk ditafsirkan dalam konteks yang lebih nyata. Rumus RMSE:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

y_i = nilai aktual pada datai

$\hat{y}_i$ = nilai prediksi pada datai

n = jumlah data

2.4.3. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) adalah rata-rata nilai absolut dari selisih antara nilai prediksi dan aktual. MAE memberikan penilaian yang lebih mudah dan dapat dimengerti, menghitung kesalahan rata-rata tanpa memberikan penalti kesalahan yang signifikan seperti pada MSE atau RMSE. Rumus MAE:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (15)$$

y_i = nilai aktual pada datai

$\hat{y}_i$ = nilai prediksi pada datai

n = jumlah data

2.4.4. Coefficient of Determination (R^2)

Coefficient of Determination digunakan untuk mengevaluasi seberapa baik model regresi memprediksi data aktual. Nilainya adalah 0 hingga 1, dengan nilai yang mendekati 1 menunjukkan model yang lebih baik. Rumusnya adalah:

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (16)$$

Deskripsi:

SS_{res} Adalah jumlah kuadrat sisa:

$$SS_{res} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

Dimana:

y_i = Nilai aktual

$\hat{y}_i$ = Nilai yang diprediksi

Adalah jumlah total kuadrat:

$$SS_{tot} = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (18)$$

Mana:

$\bar{y}$ = Nilai aktual rata-rata

Interpretasi


$R^2 = 1$: Modelnya sempurna; Semua prediksi cocok dengan data.

$R^2 = 0$: Model sama sekali tidak menjelaskan variabilitas data.

R^2 Negatif: Model ini lebih buruk daripada menggunakan rata-rata sebagai prediksi.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode prediksi berbasis model Long Short-Term Memory (LSTM). Proses penelitian melibatkan beberapa tahapan utama: pengumpulan data, praproses, pemodelan, evaluasi model, dan interpretasi hasil.



Gambar 2. Tahapan penelitian

Gambar 2 menjelaskan tahapan penelitian dilakukan sesuai dengan penjelasan dibawah:

- Pengumpulan Data, Data saham Indofood Sukses Makmur (INDF) diperoleh melalui Yahoo Finance API dengan rentang waktu 1 Desember 2014 hingga 6 Desember 2024. Data yang diambil mencakup lima parameter utama, yaitu harga pembukaan (*Open*), harga tertinggi (*High*), harga penutupan (*Close*), harga terendah (*Low*), dan volume transaksi harian (*Volume*).
- Prapemrosesan Data, Data yang telah diperoleh dibersihkan untuk menghapus nilai kosong atau tidak valid, lalu dinormalisasi menggunakan metode *Min-Max Scaling* agar seluruh fitur berada dalam skala 0 hingga 1. Normalisasi ini bertujuan mempercepat konvergensi model saat

pelatihan. Selanjutnya, dilakukan perhitungan indikator teknikal yaitu EMA (periode 4, 9, dan 18), RSI, MACD, dan *Close Lag* (1, 2, dan 3).

- Pembagian Dataset dan Pemilihan Fitur, Dataset dibagi menjadi tiga bagian: Data *Train* 70%, Data *Validation* 15%, dan Data *Test* 15%. Pembagian ini dilakukan secara berurutan (time series split) untuk menjaga urutan waktu. Selanjutnya, dilakukan pemilihan fitur indikator teknikal yaitu EMA (periode 4, 9, dan 18), RSI, MACD, dan *Close Lag* (1, 2, dan 3).
- Pemodelan LSTM, Model dibangun menggunakan library PyTorch, dengan arsitektur sebagai berikut: 1 *Layer* LSTM dengan 64 unit neuron untuk menangkap pola sekuensial, diikuti oleh 1 *Fully Connected Layer* sebagai *output*. Model dilatih menggunakan dataset yang mencakup fitur indikator teknikal seperti EMA, RSI, dan MACD.
- Pengujian Model dan Evaluasi, Pengujian dilakukan menggunakan data uji untuk mengevaluasi kemampuan model dalam memprediksi harga saham yang belum pernah dilihat sebelumnya. Model dilatih selama 250 epoch, dan performanya diukur menggunakan metrik *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE) untuk mengetahui tingkat kesalahan prediksi, serta R^2 Score untuk mengukur tingkat akurasi model dalam menjelaskan variabilitas data aktual.
- Analisis Hasil, yang menafsirkan kinerja model dan relevansi indikator teknis dengan prediksi harga saham.

4. HASIL DAN PEMBAHASAN

4.1. Visualisasi Dataset

Periode dataset saham INDF dimulai dari 1 Desember 2014 hingga 6 Desember 2024, dengan data harga saham harian yang mencerminkan tingkat aktivitas pasar terhadap saham tersebut. Berikut adalah grafik saham INDF:



Gambar 3. Grafik Harga Penutupan Saham INDF untuk periode 2014 hingga 2024

Pada gambar 3 dapat dilihat awal tahun 2020 menjadi peristiwa bersejarah seiring penyebaran virus COVID-19 dan menimbulkan kegemparan di seluruh dunia. COVID-19 dapat menyebabkan dataset saham menjadi tidak *reliable* untuk digunakan, tetapi saham INDF menunjukkan bahwa saham ini tidak mengalami dampak yang sangat signifikan sesuai dengan grafik gambar 3.

4.2. Prapemrosesan Data

Data time series yang sudah dikumpulkan dari Yahoo Finance API diproses agar optimal dalam pelatihan model. Meliputi beberapa langkah berikut:

- Pembersihan Data:** Menghapus nilai kosong (missing values) dan data tidak valid dengan metode forward fill dan dropna untuk memastikan data bersih.
- Perhitungan Indikator Teknikal:** Menghitung indikator teknikal seperti Exponential Moving Average (EMA) periode 4, 9, dan 18, Relative Strength Index (RSI), serta Moving Average Convergence Divergence (MACD) dan Signal Line. Ditambahkan pula fitur Close Lag 1, 2, dan 3 untuk menangkap pola historis harga.
- Normalisasi Data:** Seluruh fitur dinormalisasi menggunakan Min-Max Scaling agar berada dalam rentang 0 hingga 1. Normalisasi ini bertujuan mempercepat proses pelatihan model dan menjaga stabilitas pembelajaran.

Hasil prapemrosesan menghasilkan dataset dengan total 13 fitur yang siap digunakan dalam proses pelatihan model LSTM.

4.3. Visualisasi Indikator Teknikal

4.3.1. Analisis Triple EMA

Berikut ini adalah hasil *output* fitur menggunakan indikator teknikal EMA 4, EMA 9, dan EMA 18 pada harga saham Indofood Sukses Makmur dari tahun 2014 hingga 2024.

Exponential Moving Averages Visualization EMA_4, EMA_9 & EMA_18




Gambar 4. Grafik Triple Exponential Moving Average saham Indofood Makmur Sukses periode 2014 hingga 2024

Pada Gambar 4 menunjukkan visualisasi dari *Exponential Moving Averages* (EMA) dengan periode 4, 9, dan 18 untuk saham INDF. EMA 4 (Merah) EMA dengan periode 4 hari menunjukkan tren jangka pendek dan respons cepat terhadap perubahan harga. EMA 9 (Hijau) dengan periode 9 hari yang menunjukkan tren jangka menengah dan memberikan gambaran yang lebih stabil dibandingkan EMA 4. EMA 18 (Ungu) dengan periode 18 hari yang menunjukkan tren jangka panjang dan memberikan gambaran yang lebih stabil dibandingkan EMA 9 dan EMA 4.

4.3.2. Analisis RSI

Berikut ini adalah hasil *output* fitur yang ditunjukkan dengan menggunakan indikator teknikal

RSI pada harga saham Indofood Sukses Makmur dari tahun 2014 hingga 2024.




Gambar 5. Grafik Teknis Indikator Relative Strength Index saham Indofood Makmur Sukses periode 2014 hingga 2024

Pada Gambar 5 grafik RSI selama 10 tahun menunjukkan bahwa INDF pernah menyentuh nilai di atas 70 biasanya *overbought* (jenuh beli) dan nilai di bawah 30 *oversold* (jenuh jual).

4.3.3. Analisis MACD dan Signal Line

Berikut ini adalah hasil *output* fitur menggunakan indikator teknikal MACD dan *Signal Line* pada harga saham Indofood Makmur dari tahun 2014 hingga 2024.




Gambar 6. Grafik Moving Average Convergence Divergence & Signal Line saham Indofood Makmur Sukses dari tahun 2014 hingga 2024

Pada Gambar 6, garis merah merepresentasikan MACD, sedangkan garis hijau adalah *Signal Line*. Persilangan antara keduanya memberikan sinyal perdagangan, di mana MACD yang memotong *Signal Line* ke atas menandakan potensi *bullish* (sinyal beli), sementara MACD yang memotong ke bawah mengindikasikan potensi *bearish* (sinyal jual).

4.3.4. Analisis Close Lag

Berikut ini adalah hasil *output* fitur menggunakan indikator teknikal Close Lagging pada harga saham Indofood Sukses Makmur dari tahun 2014 hingga 2024.



Gambar 7. Grafik Close Lagging Saham Indofood Makmur Sukses periode 2014 hingga 2024

Pada Gambar 7, garis merah mempresentasikan *Close Lag 1*, garis Hijau mempresentasikan *Close Lag 2*, dan garis ungu mempresentasikan *Close Lag 3*. Persilangan antara ketiganya memberikan sinyal perdangan *up-trend* dan *down-tren*.

4.4. Pemilihan Fitur

Pemilihan fitur dalam penelitian ini dilakukan untuk memastikan bahwa model dilatih menggunakan variabel yang relevan dengan pergerakan harga pasar. Dataset yang digunakan mencakup beberapa kelompok fitur utama, yaitu harga pasar, indikator teknikal, dan fitur *Close Lagging*. Fitur harga pasar meliputi *Open* (harga pembukaan), *High* (harga tertinggi), *Low* (harga terendah), *Close* (harga penutupan), dan *Volume* (volume perdagangan). Indikator teknikal yang digunakan mencakup *EMA_4*, *EMA_9*, dan *EMA_18* sebagai rata-rata pergerakan eksponensial yang menangkap tren jangka pendek hingga menengah, *RSI* (*Relative Strength Index*) untuk mengukur momentum pasar, serta *MACD* (*Moving Average Convergence Divergence*) dan *Signal Line* sebagai indikator tren. Selain itu, fitur *Close Lagging*,

seperti *Close_Lag1*, *Close_Lag2*, dan *Close_Lag3*, ditambahkan untuk memberikan informasi historis langsung tentang harga penutupan 1, 2, dan 3 hari sebelumnya. Kombinasi fitur ini dirancang untuk memberikan keseimbangan antara data historis langsung dan indikator teknis yang lebih kompleks sehingga model dapat mengenali pola tren, volatilitas, maupun momentum dalam data deret waktu.

4.5. Hasil Pengujian dan Evaluasi Model LSTM

Penerapan model *Long Short-Term Memory* (LSTM) untuk memprediksi harga saham INDF. Meliputi *input* yang terdiri dari total 13 fitur. Di sini, jumlah unit tersembunyi adalah 64 untuk bertujuan menangkap pola temporal dalam data. Selama pelatihan yang dilakukan dalam 250 *epoch*.

Tabel 1. Hasil 10 train terakhir & uji validasi 250 epoch model LSTM

<i>Epoch</i>	<i>Train Loss</i>	<i>Validation Loss</i>	<i>MSE</i>	<i>RMSE</i>	<i>MAE</i>	<i>R² Score</i>
240	0.0008	0.0002	0.0002	0.0156	0.0118	0.9387
241	0.0008	0.0004	0.0004	0.0206	0.0164	0.8929
242	0.0010	0.0003	0.0003	0.0164	0.0124	0.9324
243	0.0008	0.0002	0.0002	0.0155	0.0117	0.9395
244	0.0008	0.0003	0.0003	0.0179	0.0138	0.9194
245	0.0008	0.0002	0.0002	0.0156	0.0118	0.9385
246	0.0008	0.0003	0.0003	0.0159	0.0121	0.9359
247	0.0008	0.0003	0.0003	0.0178	0.0137	0.9195
248	0.0008	0.0003	0.0003	0.0160	0.0121	0.9353
249	0.0009	0.0003	0.0003	0.0163	0.0124	0.9327
250	0.0008	0.0004	0.0004	0.0190	0.0148	0.9084


Pada tabel 1 Hasil pelatihan menunjukkan *Train Loss* menggambarkan kesalahan prediksi model terhadap data pelatihan, sementara *Validation Loss* menunjukkan kesalahan prediksi terhadap data validasi yang tidak digunakan dalam pelatihan. Penurunan konsisten pada *Train Loss* dan *Validation Loss*, serta peningkatan *R² Score*, menunjukkan model belajar efektif dan mampu menggeneralisasi dengan baik pada data baru. Metrik kesalahan seperti *MSE*, *RMSE*, dan *MAE* yang menurun mengindikasikan peningkatan akurasi prediksi harga saham. Nilai kesalahan cenderung menurun seiring bertambahnya epoch, dan skor *R²* yang tinggi (di atas 0,9) menunjukkan bahwa model LSTM berhasil mempelajari pola historis dengan baik.

Tabel 2. Hasil test model LSTM

<i>MSE</i>	<i>RMSE</i>	<i>MAE</i>	<i>R² Score</i>
0.0010	0.0316	0.0244	0.9232


Pada tabel 2 model diuji menggunakan data pengujian untuk mengevaluasi kinerja prediksi terhadap nilai aktual. Hasil evaluasi menunjukkan bahwa model dapat mencapai nilai *Mean Squared Error* (*MSE*) sebesar 0,0010, *Root Mean Squared Error* (*RMSE*) sebesar 0,0316, dan *Mean Absolute Error* (*MAE*) sebesar 0,0244. Skor *R²* yang diperoleh adalah 0,9232, menunjukkan bahwa model tersebut dapat menjelaskan 92,32% dari varians data target.

Nilai kesalahan yang rendah dan skor *R²* yang tinggi menunjukkan model ini memiliki kemampuan prediksi yang sangat baik untuk pola data deret waktu.



Gambar 8. Fitur-fitur yang penting model LSTM

Pada Gambar 8 Dilakukan analisis pentingnya fitur untuk memahami kontribusi masing-masing variabel input terhadap prediksi model. Metode berbasis gradien (*saliency analysis*) digunakan untuk mengukur sensitivitas prediksi model terhadap perubahan nilai fitur *input*. Hasil analisis menunjukkan bahwa fitur '*Close*' memiliki pengaruh terbesar terhadap prediksi, diikuti oleh '*High*', '*EMA_4*', dan '*Close_Lag1*'. Temuan ini mengindikasikan bahwa model memanfaatkan informasi historis, terutama harga penutupan, sebagai faktor utama dalam menentukan prediksi masa depan. Selain itu, fitur tambahan seperti '*RSI*' dan '*MACD*' juga memberikan kontribusi, meskipun dalam skala yang lebih kecil.




Gambar 9. Prediksi harga Penutupan INDF untuk 10 hari ke depan

Pada Gambar 9, model menunjukkan prediksi harga saham INDF untuk periode 10 hari ke depan. Berdasarkan visualisasi prediksi harga saham, tren pada periode ini mengalami *down-trend*, sehingga harga saham cenderung mengalami penurunan.

Pada Gambar 10, model menunjukkan prediksi harga saham berdasarkan model LSTM yang telah dibuat, dibandingkan dengan harga aktual saham INDF. Harga aktual ditampilkan dengan garis berwarna biru, sedangkan prediksi harga ditampilkan dengan garis kuning putus-putus. Hasil visualisasi

mengindikasikan bahwa model mampu memprediksi harga saham dengan baik.



Gambar 10. Uji aktual dan prediksi model LSTM

4.6. Evaluasi Model Berdasarkan Variasi Epoch dan Data Split

Dilakukan penelitian lebih lanjut untuk mengetahui perbandingan hasil model LSTM berdasarkan variasi epoch dan dataset yang digunakan. Hasil dari pelatihan dan validasi model dapat dilihat pada tabel 3.

Tabel 3. Perbandingan Data Train & Data Validation Variasi Epoch & Dataset

Epoch	Dataset	MSE	RMSE	MAE	R ² Score
100	90/5/5	0.0003	0.0160	0.0121	0.7745
250	70/15/15	0.0004	0.0190	0.0148	0.9084
500	80/10/10	0.0004	0.0192	0.0152	0.9418

Pada Tabel 3 dapat dijelaskan bahwa peningkatan jumlah epoch dan variasi pembagian data memberikan dampak terhadap performa model. Pada epoch 100 dengan dataset *training* 90%, *validation* 5%, *test* 5% model menunjukkan error yang rendah namun nilai R² Score lebih kecil dibandingkan skenario lainnya. Model dengan epoch 250 dan dataset *training* 70%, *validation* 15%, *test* 15% memiliki keseimbangan antara *error* dan akurasi, sedangkan model dengan epoch 500 dan dataset *training* 80%, *validation* 10%, *test* 10% menunjukkan R² Score tertinggi.

Untuk mengetahui hasil dari *test* model berdasarkan variasi epoch dan dataset dapat dilihat pada tabel 4.

Tabel 4. Perbandingan Data Test Variasi Epoch & Dataset

Epoch	Dataset	MSE	RMSE	MAE	R ² Score
100	90/5/5	0.0007	0.0266	0.0200	0.9701
250	70/15/15	0.0010	0.0316	0.0244	0.9232
500	80/10/10	0.0007	0.0270	0.0194	0.9605

Pada tabel 4 hasil pengujian pada data *test*, model dengan epoch 100 dan dataset *training* 90%, *validation* 5%, *test* 5% menghasilkan R² Score tertinggi yaitu 0,9701, meskipun dengan jumlah epoch yang lebih sedikit. Hal ini menunjukkan bahwa model cukup efektif dalam kondisi tertentu meskipun dilatih dalam waktu singkat. Sementara itu, model dengan epoch

500 dan dataset *training* 80%, *validation* 10%, *test* 10% menunjukkan performa stabil dengan error yang rendah dan akurasi yang tinggi. Secara keseluruhan, variasi epoch dan dataset memberikan pengaruh yang signifikan terhadap hasil prediksi, sehingga pemilihan konfigurasi pelatihan model harus disesuaikan dengan kebutuhan dan efisiensi proses pelatihan.

5. KESIMPULAN DAN SARAN

Model *Long Short-Term Memory* (LSTM) terbukti efektif dalam memprediksi harga saham Indofood Sukses Makmur (INDF) dengan tingkat akurasi tinggi (R² Score: 0,9232) dan kesalahan prediksi rendah (MSE: 0,0010, RMSE: 0,0316, MAE: 0,0244) pada skenario pelatihan 250 epoch dengan dataset *training* 70%, *validation* 15%, *test* 15%. Evaluasi tambahan menunjukkan bahwa variasi epoch dan pembagian dataset memberikan pengaruh signifikan terhadap performa model, di mana model dengan 100 epoch dan dataset *training* 90%, *validation* 5%, *test* 5% mencapai R² Score tertinggi pada data uji (0,9701), sementara 500 epoch dengan dataset *training* 80%, *validation* 10%, *test* 10% menghasilkan performa stabil dengan *error* rendah. Hal ini menegaskan pentingnya pemilihan konfigurasi pelatihan yang optimal sesuai kebutuhan. Model LSTM dapat menjadi alat bantu prediksi saham yang andal, namun penelitian ini masih memiliki keterbatasan karena belum mempertimbangkan data fundamental dan faktor eksternal pasar. Saran untuk

penelitian selanjutnya adalah memperluas pengujian pada perusahaan sektor lain, menambahkan variabel fundamental, serta mengoptimalkan parameter pelatihan agar model memiliki generalisasi dan keandalan lebih baik dalam berbagai kondisi pasar.

DAFTAR PUSTAKA

- [1] IDX, "Saham." Accessed: Dec. 09, 2024. [Online]. Available: <https://www.idx.co.id/id/produk/saham/>
- [2] X. Song *et al.*, "Time-series well performance prediction based on Long Short-Term Memory (LSTM) neural network model," *J Pet Sci Eng*, vol. 186, Mar. 2020, doi: 10.1016/j.petro.2019.106682.
- [3] T. Badriatin, L. R. Rinandiyana, and W. S. Marino, "Persepsi Risiko dan Sikap Toleransi Risiko terhadap Keputusan Investasi Mahasiswa," 2022, doi: 10.31294/jp.v17i2.
- [4] J. Akuntansi dan Keuangan Fakultas Ekonomi dan Bisnis, A. Rachman Rika, J. Pendidikan Akuntansi FKIP Universitas Halu Oleo, and J. Akuntansi Fakultas Ekonomi dan Bisnis Universitas Halu Oleo, "Studi Kasus Investor Di MNC Trade Syariah Kendari," *Jurnal Akuntansi dan Keuangan (JAK)*, vol. 7, no. 2, 2022, [Online]. Available: <http://jak.uho.ac.id/index.php/journal/issue/archive>
- [5] M. A. L. H. LBS and K. Khairunnisa, "HARI PERDAGANGAN: ABNORMAL RETURN DAN VOLATILITAS RETURN SAHAM," *Jurnal Riset Ilmu Ekonomi*, vol. 2, no. 3, pp. 149–161, Jan. 2023, doi: 10.23969/jrie.v2i3.34.
- [6] M. Zuliyana, W. Arista Valendra, D. jurusan Akuntansi, U. Tridianti, and S. Selatan, "PENGARUH RISIKO KREDIT DAN RISIKO PASAR TERHADAP HARGA SAHAM PADA PERUSAHAAN PERBANKAN YANG TERDAFTAR DI INDONESIA STOCK EXCHANGE (IDX) PERIODE 2014-2016," *Jurnal Kompetitif*, vol. 10, no. 2, 2021, [Online]. Available: <http://www.univ-tridianti.ac.id/ejournal/index.php/ekonomi/index>
- [7] N. Nurliandini, E. H. Juniwati, and S. Setiawan, "Analisis Pengaruh Faktor Fundamental, Teknikal dan Makro Ekonomi Terhadap Harga Saham Pada Perusahaan Subsektor Kimia yang Terdaftar di Indeks Saham Syariah," *Journal of Applied Islamic Economics and Finance*, vol. 2, no. 1, pp. 35–47, Oct. 2021, doi: 10.35313/jaief.v2i1.2907.
- [8] Y. R. Indah and L. P. Mahyuni, "The Accuracy of Relative Strength Index (RSI) Indicator in Forecasting Foreign Exchange Price Movement," Apr. 2022.
- [9] Y. Han, Y. Liu, G. Zhou, and Y. Zhu, "Technical Analysis in the Stock Market: A Review," *SSRN Electronic Journal*, May 2021, doi: 10.2139/ssrn.3850494.
- [10] K. R. Dahal, A. Gupta, and N. R. Pokhrel, "Predicting the Direction of NEPSE Index Movement with News Headlines Using Machine Learning," *Econometrics*, vol. 12, no. 2, Jun. 2024, doi: 10.3390/econometrics12020016.
- [11] T. B. Sianturi, I. Cholissodin, and N. Yulistira, "Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum," 2023. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [12] G. Van Houdt, C. Mosquera, and G. Nápoles, "A review on the long short-term memory model," *Artif Intell Rev*, vol. 53, no. 8, pp. 5929–5955, Dec. 2020, doi: 10.1007/s10462-020-09838-1.
- [13] A. N. Rachmi, "IMPLEMENTASI METODE RANDOM FOREST DAN XGBOOST PADA KLASIFIKASI CUSTOMER CHURN," Yogyakarta, Nov. 2020.
- [14] K. Aqbar and R. A. Supomo, "Performance Analysis of LSTM and XGBoost Models Optimization in Forecasting Crude Palm Oil (CPO) Production at Palm Oil Mill (POM)," *Int J Comput Appl*, vol. 185, no. 17, pp. 37–44, Jun. 2023, doi: 10.5120/ijca2023922890.
- [15] M. Ula, V. Ilhadi, and Z. M. Sidek, "Comparing Long Short-Term Memory and Random Forest Accuracy for Bitcoin Price Forecasting," *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 23, no. 2, pp. 259–272, Jan. 2024, doi: 10.30812/matrik.v23i2.3267.
- [16] A. Moghar and M. Hamiche, "Stock Market Prediction Using LSTM Recurrent Neural Network," in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 1168–1173. doi: 10.1016/j.procs.2020.03.049.
- [17] M. Istaltofa and A. Sucipto, "Comparison of Linear Regression and LSTM (Long Short-Term Memory) in Cryptocurrency Prediction," *Journal of Dinda Data Science, Information Technology, and Data Analytics*, vol. 4, no. 2, pp. 141–148, 2024, [Online]. Available: <http://journal.ittelkom-pwt.ac.id/index.php/dinda>
- [18] Khalis Sofi, Aswan Supriyadi Sunge, Sasmitoh Rahmad Riady, and Antika Zahrotul Kamalia, "PERBANDINGAN ALGORITMA LINEAR REGRESSION, LSTM, DAN GRU DALAM MEMPREDIKSI HARGA SAHAM DENGAN MODEL TIME SERIES," *SEMINASTIKA*, vol. 3, no. 1, pp. 39–46, Nov. 2021, doi: 10.47002/seminastika.v3i1.275.
- [19] M. Selim, R. Zhou, W. Feng, and P. Quinsey, "Estimating energy forecasting uncertainty for reliable ai autonomous smart grid design," *Energies (Basel)*, vol. 14, no. 1, Jan. 2021, doi: 10.3390/en14010247