

Implementasi Model BiLSTM-Attention untuk Prediksi Nilai IHSG Berdasarkan Data Historis OHLCV

Safira Rahmalia Putri¹, Amirah Rizky Ramadhanti², Trimono^{3*}, Mohammad Idhom⁴

Sains Data, Fakultas Ilmu Komputer, UPN "Veteran" Jawa Timur
Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Indonesia
22083010073@student.upnjatim.ac.id¹, 22083010036@student.upnjatim.ac.id², trimono.stat@upnjatim.ac.id³,
idhom@upnjatim.ac.id⁴

Submitted : 02/06/2025; Reviewed : 09/06/2025; Accepted : 15/08/2025; Published : 31/10/2025

Abstract

The Composite Stock Price Index (IHSG) reflects the performance of the Indonesian capital market, but predicting it is challenging due to high volatility and the influence of various external factors. This study aims to develop and evaluate a deep learning-based predictive model using a Bidirectional Long Short-Term Memory (BiLSTM) architecture combined with an Attention Mechanism to predict the IHSG value based on historical numerical data (OHLCV). This method was chosen for its ability to recognize bidirectional sequential patterns and highlight the most relevant historical information in the prediction process. The research was conducted quantitatively using an experimental approach, and model evaluation was performed using regression metrics such as R^2 , RMSE, MAE, and MAPE. The results obtained showed excellent predictive performance with an R^2 of 0.9485, MAPE of 0.63%, RMSE of 59.47, and MAE of 45.12. Additionally, attention weight analysis revealed that the model focuses more on the last two days within the prediction time window, indicating that recent information significantly influences IHSG movements. These findings suggest that the BiLSTM-Attention approach is effective in capturing stock market dynamics and has the potential to serve as a strategic tool for data-driven investment decision-making.

Keywords : attention, bidirectional lstm, deep learning, ihsg, ohlcv, stock prediction

Abstrak

Indeks Harga Saham Gabungan (IHSG) merupakan parameter utama yang merepresentasikan kinerja pasar modal Indonesia, namun pergerakannya yang fluktuatif dan dipengaruhi banyak faktor eksternal membuat prediksi IHSG menjadi tantangan tersendiri. Penelitian ini mengimplementasikan model *Bidirectional Long Short-Term Memory* (BiLSTM) dengan mekanisme *Attention* untuk memprediksi nilai IHSG berdasarkan data historis OHLCV (*Open, High, Low, Close, Volume*). Model BiLSTM dipilih karena kemampuannya dalam menangkap pola data sekuensial dua arah, sementara *Attention Mechanism* memperkuat fokus model terhadap data historis yang relevan dalam proses prediksi. Penelitian dilakukan secara kuantitatif menggunakan pendekatan *deep learning*. Hasil evaluasi menunjukkan bahwa arsitektur BiLSTM-Attention mampu menghasilkan prediksi IHSG dengan performa tinggi, yaitu R^2 sebesar 0,9485, RMSE sebesar 59,47, MAE sebesar 45,12, dan MAPE sebesar 0,63%. Temuan ini menunjukkan bahwa model efektif dalam menangkap dinamika pasar dan layak digunakan sebagai alat bantu dalam pengambilan keputusan investasi yang lebih akurat dan berbasis data.

Kata kunci : attention, bidirectional lstm, deep learning, ihsg, ohlcv, prediksi saham

1. Pendahuluan

Indeks Harga Saham Gabungan (IHSG), yang mengukur kinerja harga semua saham di Papan Utama dan Papan Pengembangan Bursa Efek Indonesia (BEI), mencerminkan tren pasar modal Indonesia [1]. Sebagai indikator utama pasar saham Indonesia, IHSG yang mencakup lebih dari 900 saham memainkan peran penting bagi investor dalam memahami tren pasar dan membuat keputusan investasi. Dalam pengaruh beberapa faktor seperti inflasi, suku bunga, dan nilai tukar rupiah, IHSG mencerminkan kompleksitas dinamika pasar modal yang menuntut pemahaman mendalam untuk pengelolaan portofolio yang efektif [1]. Dengan demikian, IHSG tidak hanya menjadi cerminan kondisi ekonomi, tetapi juga memberikan landasan strategis bagi investor untuk mengantisipasi risiko dan meningkatkan efisiensi investasi. Prediksi tren yang akurat memungkinkannya merespons fluktuasi harga pasar dengan lebih tepat, terutama dalam pasar yang semakin dinamis [2].

Namun demikian, prediksi IHSG bukanlah hal yang mudah. Fluktuasi pasar yang tinggi dan pengaruh berbagai faktor eksternal seperti isu politik, kebijakan global, serta dinamika regional menjadikan pergerakan IHSG sangat volatil dan sulit diprediksi secara konsisten [2]. Beberapa studi terkini juga

mengungkapkan bahwa pasar saham Indonesia memiliki volatilitas tinggi akibat kombinasi faktor internal dan eksternal yang saling memengaruhi [3], [4], [5]. Ketidakstabilan ini sering kali mengakibatkan performa model prediktif menjadi tidak konsisten antar waktu dan antar emiten sehingga menyulitkan investor dalam membuat keputusan cepat [6]. Apabila tantangan ini terus berlanjut, keputusan investasi akan cenderung lebih spekulatif dan rentan terhadap kerugian. Hal ini menegaskan pentingnya penggunaan pendekatan prediktif yang adaptif dan akurat.

Pendekatan konvensional seperti regresi linier atau model statistik tradisional sering kali gagal dalam menangkap kompleksitas pola nonlinier dan dependensi jangka panjang dalam data *time series* saham. Oleh karena itu, model *deep learning* mulai banyak digunakan dalam penelitian pasar modal. *Long Short-Term Memory* (LSTM) telah terbukti efektif dalam mengenali pola sekuensial dalam data historis [6], [7], sementara *Bidirectional LSTM* (BiLSTM) dapat meningkatkan akurasi dengan memproses informasi dua arah [8]. Integrasi *Attention Mechanism* dalam arsitektur ini memberikan kemampuan tambahan dalam mengidentifikasi informasi historis yang paling relevan untuk prediksi sehingga membuat model lebih fokus pada *time step* yang berdampak signifikan.

Beberapa studi menunjukkan efektivitas gabungan ini. Penelitian oleh [9] mengusung model STACN berbasis BiLSTM yang memadukan data numerik dan teks, serta berhasil meraih $MAE: 24.27$; $RMSE: 32.91$; $R^2: 0.9365$. Pada penelitian [10], dilakukan perbandingan LSTM dan BiLSTM dalam prediksi saham syariah dan menemukan BiLSTM lebih unggul berdasarkan nilai MAPE. Sementara itu, penelitian [8] menggabungkan BiLSTM dengan data sentimen Twitter untuk prediksi saham BBCA, menghasilkan nilai MSE sebesar 0.094 dan RMSE sebesar 0.306. Ketiga studi tersebut memperlihatkan potensi kuat model BiLSTM, baik menggunakan data numerik maupun dikombinasikan dengan teks.


Namun, sebagian besar studi terdahulu lebih banyak mengeksplorasi saham individual, menggunakan data sentimen, atau fokus pada pasar luar negeri. Belum banyak penelitian yang mengkaji model BiLSTM dengan *Attention* secara khusus untuk prediksi indeks pasar Indonesia berbasis numerik murni seperti data OHLCV (*Open, High, Low, Close, Volume*). Di sinilah letak *gap* penelitian ini.

Penelitian ini mengadopsi pendekatan *deep learning* berbasis BiLSTM-*Attention* yang fokus pada data numerik historis untuk memprediksi pergerakan IHSG. Inovasi dalam penelitian ini terletak pada penerapan arsitektur gabungan tersebut untuk mengenali pola temporal dua arah sekaligus menyoroti fitur historis yang paling relevan tanpa menggunakan data eksternal seperti sentimen. Pendekatan ini diharapkan dapat menjadi alternatif yang lebih adaptif dan responsif dibandingkan model prediktif konvensional.

Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi performa model BiLSTM-*Attention* dalam memprediksi tren IHSG berdasarkan data histori OHLCV, serta mengkaji potensinya dalam mendukung pengambilan keputusan investasi berbasis data.

2. Metodologi

Penelitian ini menggunakan pendekatan kuantitatif melalui metode eksperimen yang menekankan pada data *time series*. Tujuan dari penelitian ini adalah untuk mengembangkan model *deep learning* BiLSTM dengan mekanisme perhatian (*Attention Mechanism*) untuk memprediksi harga penutupan IHSG. Proses metodologinya terbagi menjadi lima tahap utama: pengumpulan data (*data collecting*), pra-proses data (*preprocessing data*), pembangunan model, pelatihan model (*training model*), dan evaluasi serta visualisasi hasil.



Gambar 1. Alur Proses Penelitian Model Prediksi IHSG

Gambar di atas menunjukkan tahapan metodologi yang digunakan dalam penelitian ini. Proses dimulai dari pengumpulan data historis IHSG yang diperoleh dari sumber terpercaya, kemudian dilanjutkan dengan pra-proses data untuk memastikan kualitas dan konsistensi informasi. Data yang telah diproses kemudian dimasukkan ke dalam arsitektur model BiLSTM yang dikombinasikan dengan *attention mechanism* untuk meningkatkan kemampuan dalam mengenali pola-pola penting. Tahap akhir dari metodologi ini adalah evaluasi kinerja model, yang dilakukan menggunakan metrik seperti MAE, MSE, dan RMSE untuk mengukur tingkat akurasi hasil prediksi.

2.1 Data Collecting

Data yang digunakan dalam penelitian ini adalah data historis Indeks Harga Saham Gabungan (IHSG), yang berfungsi sebagai indeks utama yang merefleksikan keseluruhan pergerakan harga saham di Bursa Efek Indonesia (*Jakarta Stock Exchange*). Data disusun dalam format teknikal OHLCV (*Open, High, Low, Close, Volume*), yang umum digunakan dalam analisis deret waktu di pasar saham.

Pengambilan data dilakukan melalui *platform Yahoo Finance* dengan memanfaatkan pustaka *Python 'yfinance'*, yang memungkinkan proses pengunduhan data historis secara terprogram dan efisien. Rentang waktu data yang digunakan mencakup periode 1 Januari 2018 hingga 31 Desember 2024. Untuk menjaga integritas dataset, seluruh data yang tidak lengkap, termasuk hari libur bursa dan nilai kosong (*missing values*), telah dihapus dari kumpulan data sebelum dilakukan proses analisis lebih lanjut.

2.2 Preprocessing Data

Tahapan *preprocessing* data merupakan langkah esensial di dalam penelitian yang berbasis pada data deret waktu, terutama dalam menyesuaikan data dengan kebutuhan struktur model *deep learning*. Proses ini melibatkan serangkaian langkah yang saling terhubung, yang dimulai dari transformasi angka, pembentukan struktur sekuensial, hingga pembagian dataset untuk pelatihan serta pengujian.

Langkah pertama melibatkan normalisasi angka dari seluruh fitur input dan target. Proses ini memakai *MinMaxScaler* yang berasal dari pustaka *'sklearn.preprocessing'*, yang mengubah setiap nilai fitur ke rentang [0, 1]. Tujuan utama dari normalisasi ini adalah untuk menyamakan skala di antara fitur-fitur, mencegah dominasi numerik dari fitur tertentu, dan mempercepat konvergensi selama pelatihan model. Semua kolom termasuk *'Open'*, *'High'*, *'Low'*, *'Close'*, dan *'Volume'* dikenai proses ini.

Langkah berikutnya adalah mengubah dataset menjadi struktur deret waktu menggunakan teknik *windowing*. Metode ini menyusun data historis menjadi urutan tetap yang mencakup lima hari. Setiap urutan terdiri dari lima data harian berturut-turut sebagai *input ('X')* dan satu nilai harga *'Close'* yang tercatat pada hari ke-6 sebagai *target ('y')*. Melalui penilaian terhadap beragam ukuran jendela (dari 5 hingga 90),

ditemukan bahwa ukuran jendela sama dengan 5 memberikan hasil evaluasi terbaik menurut metrik RMSE, sehingga ditetapkan sebagai pengaturan akhir.

Setelah proses pembuatan *window*, data dibagi menjadi dua bagian untuk tujuan pelatihan dan evaluasi. Sebanyak 80% dari seluruh urutan digunakan untuk melatih model, sedangkan 20% sisanya digunakan untuk uji. Pemisahan ini dilakukan secara berurutan (*chronological split*), bukan secara acak, mengingat sifat data *time series* yang memerlukan keteraturan temporal agar informasi masa lalu tetap dapat terjaga. Dengan menjaga urutan ini, proses pembelajaran model dapat mencerminkan dinamika pasar yang realistis dan mencegah kebocoran data dari masa depan ke masa lalu.

2.3 Model Construction

Model yang diterapkan dalam penelitian ini dirancang dengan memanfaatkan teknik jaringan saraf dalam (*deep neural network*) yang mengusung arsitektur *Bidirectional Long Short-Term Memory (BiLSTM)* serta mekanisme perhatian (*attention mechanism*) yang terintegrasi. Pilihan arsitektur ini didasarkan pada kemampuannya untuk menangkap interaksi temporal dalam data deret waktu dari kedua arah, baik dari masa lalu menuju masa depan maupun sebaliknya, guna menganalisis pola fluktuasi harga saham.

Dalam analisis data deret waktu, pendekatan berbasis *deep learning* telah menjadi populer karena mampu mengenali pola kompleks dari data sekuensial. Salah satu pendekatan yang paling relevan adalah *Recurrent Neural Network (RNN)* dan *Long Short-Term Memory (LSTM)*. RNN dan LSTM dirancang untuk memproses data urut dan sangat efektif dalam tugas prediksi yang berbasis waktu [11]. LSTM diciptakan khusus untuk menangani masalah *vanishing gradient* yang umum terjadi pada RNN saat menangani ketergantungan jangka panjang. Meskipun demikian, LSTM juga memiliki batasan karena hanya mempertimbangkan arah waktu dari masa lalu ke masa depan. Untuk mengatasi hal ini, digunakanlah BiLSTM yang memungkinkan model mempertimbangkan informasi dari dua arah waktu, yang sangat penting untuk konteks prediksi seperti harga saham [12].

Secara matematis, struktur LSTM terdiri dari tiga gerbang utama: *forget gate* (f_t), *input gate* (i_t), dan *output gate* (o_t), *cell state* (c_t), dan *hidden state* (h_t). Proses kerja LSTM dapat dijelaskan dengan rumus sebagai berikut [10].

$$f_t = \sigma(W_{fh}[h_{t-1}], W_{fx}[x_t], b_f) \quad (1)$$

$$i_t = \sigma(W_{ih}[h_{t-1}], W_{ix}[x_t], b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(W_{ch}[h_{t-1}], W_{cx}[x_t], b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{c}_t \quad (4)$$

$$O_t = \sigma(W_{oh}[h_{t-1}], W_{ox}[x_t], b_o) \quad (5)$$

$$h_t = O_t * \tanh(C_t) \quad (6)$$

Untuk mengatasi keterbatasan LSTM yang hanya memproses data dalam satu arah, dikembangkanlah BiLSTM yang memproses data dalam dua arah, yaitu maju (*forward*) dan mundur (*backward*). Hasil dari kedua arah ini kemudian digabungkan untuk memperkaya konteks informasi temporal. Rumus dasar BiLSTM dirumuskan sebagai berikut.

$$\vec{h}_t = LSTM_{forward}(x_t, \vec{h}_{t-1}) \quad (7)$$

$$\bar{h}_t = LSTM_{backward}(x_t, \bar{h}_{t+1}) \quad (8)$$

$$h_t = [\vec{h}_t; \bar{h}_t] \quad (9)$$

BiLSTM memungkinkan model untuk mempertimbangkan baik informasi sebelumnya maupun informasi mendatang dalam urutan data, yang sangat penting dalam konteks prediksi deret waktu seperti harga saham [13].

Input untuk model ini tersusun dalam bentuk matriks berukuran (5, 5), di mana lima baris menggambarkan lima hari yang lalu dan lima kolom menyimpan fitur teknikal yang mencakup *'Open'*, *'High'*, *'Low'*, *'Close'*, dan *'Volume'*. Data ini pertama kali diproses melalui lapisan *BiLSTM*, yang memberikan representasi sekuensial dari waktu dengan mempertimbangkan kedua arah. *Output* yang dihasilkan dari

BiLSTM kemudian dialirkan ke lapisan *attention*, yang berperan dalam menghitung bobot relevansi setiap titik waktu dalam urutan tersebut. Mekanisme ini memberikan kemampuan pada model untuk menitikberatkan pada segmen-segmen data historis yang paling krusial untuk analisis prediksi, dan menciptakan vektor konteks (*context vector*) yang lebih padat dan kaya informasi.

Attention mechanism adalah metode dalam jaringan saraf yang memungkinkan model fokus pada bagian input yang paling relevan. Mekanisme ini meningkatkan performa dengan memberi bobot lebih pada fitur penting saat pelatihan [14]. Dalam studi Lou et al. [15], *Attention Mechanism* dikombinasikan dengan *BiLSTM* untuk prediksi harga aset seperti emas dan Bitcoin. Hasil penelitian menunjukkan bahwa integrasi ini mampu memperbaiki akurasi model, karena *attention* memberikan konteks tambahan terhadap *output* *BiLSTM* dengan menyoroti bagian data historis yang paling berpengaruh terhadap pergerakan harga. Hal ini membuat *attention mechanism* sangat berguna dalam memahami dinamika pasar yang kompleks dan fluktuatif. Secara matematis, *attention mechanism* dapat dirumuskan sebagai berikut [16].

$$e_t = \tanh(W_a h_t + b_a) \quad (10)$$

$$a_t = \frac{\exp(e_t)}{\sum_{k=1}^T \exp(e_k)} \quad (11)$$

$$s = \sum_{t=1}^T a_t h_t \quad (12)$$

Vektor konteks yang diperoleh dari lapisan *attention* selanjutnya diproses oleh lapisan *Dense* yang memiliki 32 *neuron* dan menggunakan fungsi aktivasi *ReLU*. Fungsi lapisan ini adalah untuk melakukan transformasi *non-linear* sebelum melanjutkan ke lapisan *output*. Pada tahap *output*, digunakan satu *neuron* tanpa fungsi aktivasi (*linear*) untuk memberikan nilai prediksi berupa harga penutupan (*Close*) untuk hari berikutnya.

Model ini dikompilasi dengan menggunakan fungsi kerugian *Mean Squared Error (MSE)* karena tugas yang dikerjakan bersifat regresi, dan dioptimalkan dengan algoritma Adam. Dalam proses *training*, model dioperasikan hingga jumlah maksimum 100 *epoch* dengan ukuran *batch* sebesar 32. Sebagai langkah mitigasi terhadap *overfitting*, diterapkan mekanisme *early stopping* dengan toleransi (*patience*) sebanyak 10 *epoch*. Validasi dilakukan dengan mengambil 10% dari data pelatihan selama pelatihan berlangsung, sehingga model dapat dievaluasi kemampuannya terhadap data yang tidak terlihat sebelumnya selama proses pembelajaran.

2.4 Model Training

Proses pelatihan (*training model*) dilakukan dengan memanfaatkan data berbentuk deret waktu yang telah dibagi-bagi menjadi beberapa kelompok. Model dikembangkan untuk memahami pola yang telah terjadi sebelumnya dan untuk menghasilkan prediksi harga penutupan IHSG dengan mengurangi tingkat kesalahan dalam prediksi. Data untuk latihan disusun dalam *batch* yang masing-masing berjumlah 32 dan diproses melalui beberapa siklus hingga model mendapatkan hasil yang maksimal. Selama proses pelatihan, sebagian dari data (10%) digunakan sebagai data untuk validasi agar dapat mengawasi sejauh mana model dapat menggeneralisasi terhadap data baru yang tidak dijumpai secara langsung saat tahap latihan.

2.5 Evaluasi Model dan Visualisasi Hasil

Setelah proses pelatihan selesai, model dievaluasi menggunakan data pengujian untuk menilai kinerjanya secara objektif. Penilaian dilakukan dengan metrik-metrik seperti *Mean Absolute Percentage Error (MAPE)*, *Root Mean Squared Error (RMSE)*, *Mean Absolute Error (MAE)*, dan koefisien determinasi (R^2). Selain evaluasi numerik, juga dilakukan visualisasi hasil prediksi serta distribusi perhatian agar dapat memahami perilaku model secara kualitatif. Visualisasi ini mencakup grafik yang membandingkan prediksi terhadap data aktual dan representasi *heatmap* dari bobot perhatian di setiap langkah waktu.

3. Hasil dan Pembahasan

Penelitian ini dilakukan dengan mengikuti tahapan yang telah dijelaskan dalam metodologi sebelumnya. Proses dimulai dari pengumpulan data numerik historis IHSG, pemrosesan data dengan normalisasi dan pembentukan *sequence*, perancangan arsitektur model *BiLSTM-Attention*, hingga *training* dan evaluasi model. Evaluasi dilakukan untuk mengukur akurasi prediksi nilai IHSG berdasarkan sejumlah metrik seperti RMSE, MAE, R^2 , dan MAPE, serta visualisasi tren prediksi terhadap data aktual.

Bagian ini menyajikan hasil dari implementasi model *BiLSTM-Attention* untuk prediksi nilai Indeks Harga Saham Gabungan (IHSG) berdasarkan data historis. Setiap tahap mulai dari pengumpulan data, pra-proses,

konstruksi model, pelatihan, hingga evaluasi performa model dibahas secara sistematis untuk menunjukkan efektivitas pendekatan yang digunakan.

3.1 Data Collecting

Penelitian ini menggunakan data numerik historis yang diperoleh melalui pustaka *yfinance* dengan kode indeks [^]JKSE, mewakili IHSG. Data dikumpulkan untuk periode 1 Januari 2018 hingga 31 Desember 2024, yang mencakup sekitar 1.696 hari aktif bursa selama tujuh tahun. Setiap baris data mewakili satu hari perdagangan dan terdiri dari lima fitur utama, yaitu *Open*, *High*, *Low*, *Close*, dan *Volume*.

Tabel 1. Cuplikan Data Historis IHSG Tahun 2018—2024

Date	Price				
	Close	High	Low	Open	Volume
2018-01-02	6339.237793	6445.910156	6326.092773	6366.083008	52168200
2018-01-03	6251.479004	6342.190918	6220.694824	6341.270996	48866400
2018-01-04	6292.320801	6292.320801	6233.937012	6257.716797	57864900
2018-01-05	6353.737793	6353.737793	6278.724121	6279.457031	74223700
2018-01-08	6385.403809	6385.403809	6349.041992	6354.361816	66702400
...	...	...	...	...	...
2024-12-20	6983.865234	7032.400879	6931.581055	6980.174805	145749700
2024-12-23	7096.444824	7096.444824	7035.727051	7037.529785	138664700
2024-12-24	7065.746094	7120.576172	7063.754883	7115.637207	110632900
2024-12-27	7036.570801	7100.270020	7024.714844	7073.375000	144277600
2024-12-30	7079.904785	7079.904785	6993.071777	7026.776855	159672400

Tabel 1 menyajikan cuplikan data historis indeks harga saham gabungan (IHSG) dari tahun 2018 hingga 2024 yang diunduh melalui pustaka *yfinance*. Data ini mencakup lima atribut utama yaitu harga pembukaan (*Open*), harga tertinggi (*High*), harga terendah (*Low*), harga penutupan (*Close*), dan volume perdagangan (*Volume*) untuk setiap hari perdagangan. Data tersebut menunjukkan fluktuasi harian harga IHSG yang mencerminkan dinamika pasar saham Indonesia dalam periode waktu yang cukup panjang.

Penelitian ini hanya menggunakan data numerik tanpa melibatkan data teks atau sentimen berita. Dengan fokus pada fitur numerik (OHLCV), penelitian ini bertujuan mengevaluasi sejauh mana model BiLSTM-*Attention* dapat melakukan prediksi IHSG secara akurat dengan *input* yang sederhana tetapi informatif.

3.2 Data Preprocessing

Tahap ini dilakukan untuk memastikan bahwa data numerik historis yang digunakan telah bersih dan dalam format yang siap diproses oleh model.

Langkah pertama adalah pengecekan nilai kosong (*missing values*) yang biasanya muncul akibat hari libur pasar atau data yang tidak tersedia. Baris-baris dengan nilai kosong dibuang dari *dataset* karena proporsinya sangat kecil dan tidak signifikan terhadap keseluruhan data. Hal ini dilakukan untuk menghindari *error* saat proses *training* model.

Langkah kedua adalah identifikasi *outlier* pada fitur *Close* menggunakan metode *z-score*. Nilai yang memiliki skor *z* di atas 3 atau di bawah -3 dianggap *outlier* karena secara statistik menyimpang jauh dari nilai rata-rata. Ditemukan beberapa *outlier* yang muncul pada rentang 18–26 Maret 2020.

Tabel 2. Deteksi Outlier pada Fitur Close Menggunakan Z-Score

Date	Value
2020-03-18	4330.673828
2020-03-19	4105.421875
2020-03-20	4194.943848
2020-03-23	3989.517090
2020-03-24	3937.632080
2020-03-26	4338.903809

Tabel 2 menampilkan enam data *outlier* berdasarkan nilai *z-score* pada fitur *Close*. Data tersebut menunjukkan pergerakan harga yang tidak biasa dan signifikan. Alih-alih dihapus, data ini dipertahankan karena memiliki makna kontekstual yang penting. Hal ini sejalan dengan kondisi pasar saat itu yang sedang mengalami tekanan besar akibat peristiwa global.

Periode ini bertepatan dengan awal pandemi COVID-19, di mana pasar saham mengalami tekanan besar secara global, termasuk IHSG. Meskipun secara statistik merupakan *outlier*, data ini tetap dipertahankan karena mencerminkan peristiwa ekonomi yang nyata dan berdampak besar. Penghapusan data tersebut justru dapat menyebabkan model kehilangan pemahaman terhadap perilaku pasar pada kondisi ekstrem.

Langkah ketiga adalah normalisasi data menggunakan *MinMaxScaler*, yang mentransformasi semua fitur numerik ke dalam rentang $[0, 1]$. Normalisasi ini sangat penting agar tidak terjadi dominasi fitur yang memiliki skala besar (seperti *volume*) terhadap fitur lainnya selama proses *training* model.

Terakhir, dilakukan pembentukan data *time-series* menggunakan fungsi *create_sequences*. Data diubah menjadi bentuk urutan jendela waktu (*window*) untuk melatih model dalam mengenali pola urutan pergerakan IHSG. Parameter *window_size* menjadi salah satu elemen yang dioptimalkan dalam eksperimen.

3.3 Pembangunan Model

Pada tahap konstruksi model, data yang telah melalui tahap *preprocessing* digunakan sebagai *input* ke dalam arsitektur BiLSTM yang dipadukan dengan *Attention Mechanism*. Arsitektur ini dirancang untuk menangkap pola temporal dari data historis IHSG sekaligus menyaring informasi waktu yang paling relevan dalam urutan data.

Model dibangun dengan *layer input* berdimensi (*window_size*, jumlah_fitur), yang diteruskan ke *layer Bidirectional LSTM* untuk menangkap informasi dari dua arah waktu (masa lalu dan masa depan). *Output* dari BiLSTM kemudian dikirim ke blok *Attention*, yang menghasilkan *context vector* sebagai representasi yang paling penting dari urutan data.

Selanjutnya, *context vector* diproses oleh *Dense layer* dengan fungsi aktivasi ReLU untuk menghasilkan representasi non-linear yang lebih kompleks. Akhirnya, *output layer* berupa *Dense(1)* digunakan untuk menghasilkan satu nilai prediksi harga penutupan IHSG.

Model dibangun dengan *optimizer* Adam dan menggunakan fungsi kerugian *mean squared error* (MSE), yang umumnya digunakan dalam analisis regresi. Arsitektur ini dirancang untuk menghasilkan prediksi yang akurat dengan tetap menjaga efisiensi komputasi.


3.4 Model Training

Setelah arsitektur BiLSTM-Attention berhasil dibangun, tahap selanjutnya yakni *training* model menggunakan data yang telah melalui proses sebelumnya. *Dataset* dibagi menjadi dua bagian, yakni *training set* sebesar 80% dan *testing set* sebesar 20%. Data pelatihan bertujuan untuk mengoptimalkan bobot model, sementara data pengujian digunakan untuk menilai kinerja model yang telah dilatih.

Model dilatih menggunakan fungsi *loss Mean Squared Error* (MSE) karena tugas utama penelitian ini adalah regresi harga saham. *Optimizer* yang digunakan adalah Adam dengan *learning rate default* sebesar 0.001, yang bertujuan untuk mempercepat proses konvergensi. Parameter pelatihan lainnya meliputi *batch size* sebesar 32 dan maksimum *epoch* sebanyak 100, dengan *EarlyStopping* diterapkan untuk menghentikan pelatihan ketika model tidak menunjukkan perbaikan signifikan pada *validation loss*.

Selama proses pelatihan, objek *history* digunakan untuk mencatat perkembangan nilai *training loss* dan *validation loss* pada setiap *epoch*. Penelitian ini berfokus pada optimalisasi *window size* dan penerapan BiLSTM-Attention sehingga tidak menggunakan skema percobaan atau variasi konfigurasi model lain.

Grafik *training loss* dan *validation loss* menunjukkan konvergensi yang stabil sejak awal *training*, tanpa *gap* signifikan antara keduanya. Hal ini menandakan bahwa model memiliki generalisasi yang baik dan tidak *overfit* terhadap data *train*.



Gambar 2. Grafik Training Loss dan Validation Loss Selama Proses Pelatihan

Gambar 2 tersebut menunjukkan tren penurunan nilai *loss* selama pelatihan, baik pada data pelatihan maupun data validasi. Pola yang tampak mengindikasikan bahwa model mengalami proses pembelajaran yang stabil, dengan nilai *loss* menurun tajam pada awal *epoch* dan mendatar pada epoch selanjutnya. Tidak terlihat adanya gap yang signifikan antara *training loss* dan *validation loss*, yang berarti model tidak mengalami *overfitting*. Hal ini membuktikan bahwa model BiLSTM dengan *attention mechanism* mampu menangkap pola temporal data secara efektif dan melakukan generalisasi yang baik pada data yang belum pernah dilihat sebelumnya.

3.5 Evaluasi Model dan Visualisasi Hasil

Model diuji pada data uji (20% dari *dataset*), dan hasil prediksi dibandingkan dengan data aktual. Evaluasi performa dilakukan menggunakan empat metrik, antara lain RMSE, MAE, R², dan MAPE.

Model menunjukkan hasil yang sangat baik dengan nilai R² sebesar 0.9485, MAPE 0.63%, RMSE 59.47, dan MAE 45.12. Hasil ini menunjukkan bahwa model mampu memprediksi pergerakan IHSG dengan akurasi tinggi.

Model akhir dibangun dengan konfigurasi parameter sebagai berikut.


Tabel 3. Konfigurasi Parameter Model

Parameter	Nilai/Deskripsi
Window Size Terbaik	5
Jumlah unit BiLSTM	64
Dense Layer	1 hidden layer dengan 32 unit (ReLU)
Output Layer	Dense(1) tanpa aktivasi (regresi)
Optimizer	Adam (Learning rate 0.001)
Loss Function	MSE
Batch Size	32
Epoch maksimum	100 dengan early stopping (patience=10)

Tabel 3 menampilkan konfigurasi akhir dari model BiLSTM yang digunakan untuk memprediksi pergerakan IHSG. *Window size* sebesar 5 menunjukkan bahwa model menggunakan data dari lima hari sebelumnya untuk menghasilkan prediksi berikutnya. Struktur jaringan mencakup satu lapisan BiLSTM

dengan 64 unit dan satu *dense layer* berisi 32 unit dengan aktivasi ReLU, yang dirancang untuk menangkap pola waktu secara efektif tanpa membuat model terlalu kompleks. *Optimizer Adam* dengan *learning rate* 0.001 dipilih karena mampu memberikan proses pelatihan yang efisien dan stabil. Selain itu, penggunaan teknik *early stopping* dengan nilai *patience* 10 membantu menghentikan pelatihan secara otomatis saat tidak terjadi peningkatan pada data validasi, sehingga mengurangi risiko *overfitting*.

Visualisasi hasil prediksi menunjukkan bahwa kurva prediksi mengikuti tren dari kurva aktual, dengan deviasi yang sangat kecil. Hal ini mengindikasikan bahwa model tidak hanya akurat secara numerik, tetapi juga representatif secara visual terhadap dinamika pasar.



Gambar 3. Visualisasi Hasil Prediksi IHSG Menggunakan Model BiLSTM-Attention

Visualisasi pada Gambar 3 menunjukkan perbandingan antara nilai aktual dan prediksi harga penutupan IHSG. Pola pergerakan kedua garis tampak sangat berdekatan, yang mengindikasikan bahwa model memiliki kemampuan yang baik dalam mengikuti tren pergerakan pasar. Ketepatan ini tidak hanya terlihat dari nilai *error* yang rendah, tetapi juga dari kesesuaian bentuk grafik yang dihasilkan. Dengan demikian, model dinilai cukup andal untuk memprediksi arah pergerakan IHSG berdasarkan data historis.

Selain mengevaluasi performa prediksi secara numerik, penelitian ini juga menganalisis bobot perhatian (*attention weights*) yang dihasilkan model pada setiap *timestep* dalam *window* data historis. Karena *window size* terbaik yang diperoleh adalah 5, maka setiap prediksi IHSG didasarkan pada 5 hari data sebelumnya.

Hasil rata-rata *attention weights* pada masing-masing *timestep* ditampilkan pada tabel berikut.

Tabel 4. Rata-rata Bobot Attention

<i>Timestep</i>	Rata-rata <i>Attention Weights</i>
1	0.0454
2	0.0712
3	0.1288
4	0.2503
5	0.5043

Tabel 4 menunjukkan bahwa bobot *attention* meningkat seiring dengan kedekatan waktu terhadap hari prediksi, yang mengindikasikan adanya pola temporal yang kuat dalam data IHSG. Semakin dekat data dengan waktu prediksi, semakin besar kontribusinya dalam menentukan output model. Ini mencerminkan bahwa informasi terbaru dinilai lebih relevan dibandingkan dengan data yang lebih lama. Pola distribusi bobot tersebut juga mencerminkan kemampuan model dalam menyaring informasi penting dari rangkaian waktu, yang esensial dalam konteks pasar saham yang dinamis dan sangat dipengaruhi oleh perubahan jangka pendek.

Hasil ini menunjukkan bahwa model memberikan perhatian paling besar pada data dari hari terakhir dalam jendela waktu, yakni sebesar 50.43%, disusul oleh hari ke-4 sebesar 25.03%. Sementara itu, tiga hari pertama dalam jendela waktu hanya mendapatkan perhatian yang relatif kecil. Hal ini menandakan bahwa informasi terbaru yang lebih dekat ke waktu prediksi dianggap paling relevan oleh model dalam memprediksi pergerakan IHSG.

Dengan demikian, mekanisme *attention* tidak hanya meningkatkan performa numerik model, tetapi juga memberikan interpretasi tambahan terhadap perilaku temporal IHSG, yakni bahwa pergerakan harga saham cenderung sangat dipengaruhi oleh data historis dalam 1 - 2 hari terakhir.

4. Kesimpulan

Model BiLSTM-Attention mampu memberikan performa prediksi baik terhadap pergerakan IHSG berdasarkan data numerik historis. Model ini menggabungkan kemampuan BiLSTM dan *Attention Mechanism* untuk menyoroti informasi yang relevan hingga berhasil mencapai nilai evaluasi yang tinggi, yakni R^2 sebesar 0.9485, RMSE 59.47, MAE 45.12, dan MAPE 0.63%. Hal ini menunjukkan bahwa model efektif dalam menangkap dinamika pasar saham. Namun, penelitian ini memiliki keterbatasan dalam penggunaan data yang hanya berasal dari fitur OHLCV tanpa mempertimbangkan aspek eksternal seperti sentimen berita atau indikator makroekonomi. Oleh karena itu, untuk penelitian selanjutnya disarankan untuk memperkaya model dengan integrasi data alternatif seperti sentimen media sosial atau laporan keuangan agar hasil prediksi menjadi lebih komprehensif dan konsisten dalam menghadapi variasi data.

5. Daftar Pustaka

- [1] D. R. Ningsih, N. A. Arifah Tara, and M. Muhdin, "Pengaruh Tingkat Inflasi, Suku Bunga BI, Dan Nilai Tukar Rupiah Terhadap IHSG," *JMM UNRAM - Master Of Management Journal*, vol. 10, no. 2, pp. 118–129, Jun. 2021, doi: 10.29303/jmm.v10i2.655.
- [2] M. Julian and H. Bunyamin, "Model Prediksi Harga Penutupan di Bursa Efek Indonesia dengan Menggunakan Bidirectional LSTM dan HIVE-COTE," *Jurnal Tekno Kompak*, vol. 19, no. 1, pp. 148–162, Oct. 2024, doi: 10.33365/jtk.v19i1.4599.
- [3] M. Della Sadrina, H. Hady, and F. Nalurita, "The Influence of Internal and External Variables on Stock Price Volatility in the Manufacturing Sector in Indonesia," *International Journal of Social Science and Human Research*, vol. 06, no. 07, Jul. 2023, doi: 10.47191/ijsshr/v6-i7-66.
- [4] N. A. N. Prasetya and Moh. Athoillah, "Pengaruh Faktor Eksternal Dan Internal Terhadap Indeks Harga Saham Gabungan Indonesia 2017-2022," *Contemporary Studies in Economic, Finance and Banking*, vol. 2, no. 3, pp. 531–543, Sep. 2023, doi: 10.21776/csefb.2023.02.3.15.
- [5] T. Tahmat and I. Melindyana, "Internal And External Factors On Stock Returns: Evidence From The Indonesia Stock Exchange," *Multifinance*, vol. 2, no. 2, pp. 59–69, Nov. 2024, doi: 10.61397/mfc.v2i2.259.
- [6] A. T. Haryono, R. Sarno, and K. R. Sungkono, "Stock price forecasting in Indonesia stock exchange using deep learning: a comparative study," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 14, no. 1, pp. 861–869, Feb. 2024, doi: 10.11591/ijece.v14i1.pp861-869.
- [7] T. van Klompenburg, A. Kassahun, and C. Catal, "Crop yield prediction using machine learning: A systematic literature review," *Comput Electron Agric*, vol. 177, p. 105709, Oct. 2020, doi: 10.1016/j.compag.2020.105709.
- [8] N. Afrianto, D. H. Fudholi, and S. Rani, "Prediksi Harga Saham Menggunakan BiLSTM dengan Faktor Sentimen Publik," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 41–46, Feb. 2022, doi: 10.29207/resti.v6i1.3676.
- [9] N. Anggraini, D. Arman Prasetya, and T. Trimono, "Prediksi Harga Saham Sektor Energi Menggunakan Metode Spatial Temporal Attention-Based Convolutional Network Berdasarkan

- Data Teks Dan Numerik,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 3, pp. 3872–3880, May 2025, doi: 10.36040/jati.v9i3.13443.
- [10] D. I. Puteri, “Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah,” *Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 1, pp. 35–43, May 2023, doi: 10.34312/euler.v11i1.19791.
- [11] A. Runis Makkulau and I. Yuana, “YUME : Journal of Management Penerapan Analisa Fundamental dan Technical Analysis Sebagai Upaya Dalam Meningkatkan Keinginan Investasi Mahasiswa di Pasar Modal Syariah,” *YUME : Journal of Management*, vol. 4, no. 3, pp. 165–180, 2021, doi: 10.37531/yume.vxix.432.
- [12] K. Mahendra, N. Satyahadewi, and H. Perdana, “Analisis Teknikal Saham Menggunakan Indikator Moving Average Convergence Divergence (Macd),” 2022.
- [13] D. R. Alghifari, M. Edi, and L. Firmansyah, “Implementasi Bidirectional LSTM untuk Analisis Sentimen Terhadap Layanan Grab Indonesia,” *Jurnal Manajemen Informatika (JAMIKA)*, vol. 12, no. 2, pp. 89–99, Sep. 2022, doi: 10.34010/jamika.v12i2.7764.
- [14] R. Al Kiramy, I. Permana, A. Marsal, M. R. Munzir, and M. Megawati, “Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT. Hajar Aswad,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1224–1234, Jul. 2024, doi: 10.57152/malcom.v4i4.1373.
- [15] S. H. Permatasari, I. Manfaati Nur, and F. Fauzi, “Metode Bidirectional Long Short-Term Memory (BiLSTM) Untuk Memprediksi Harga Saham BBRI Dengan Optimasi Nesterov Adaptive Moment (Nadam),” *Prosiding Seminar Nasional Unimus*, vol. 7, pp. 1151–1159, Oct. 2024.
- [16] R. W. Pratiwi, Y. Sari, and Y. Suyanto, “Attention-Based BiLSTM for Negation Handling in Sentimen Analysis,” *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 14, no. 4, pp. 397–406, Oct. 2020, doi: 10.22146/ijccs.60733.

NOMENKLATUR

x_t : Input pada waktu ke- t

h_t : Hidden state pada waktu ke- t

h_{t-1} : Hidden state dari waktu sebelumnya

C_t : Cell state pada waktu ke- t

C_{t-1} : Cell state dari waktu sebelumnya

f_t : Forget gate (mengontrol informasi yang dilupakan)

i_t : Input gate (mengontrol informasi yang ditambahkan ke memori)

$\tilde{C}_t$: Informasi kandidat untuk diperbarui ke cell state

O_t : Output gate (mengontrol keluaran ke hidden state)

σ : Fungsi aktivasi sigmoid

$\tanh$: Fungsi aktivasi hyperbolic tangent

W_f, W_h, b : Bobot dan bias yang dipelajari oleh model

$*$: Perkalian elemen-per-elemen (element-wise multiplication)

$\vec{h}_t$: Hidden state dari arah forward pada waktu ke- t

$\overleftarrow{h}_t$: Hidden state dari arah backward pada waktu ke- t

h_t : Gabungan (concatenation) dari $\vec{h}_t$ dan $\overleftarrow{h}_t$, merepresentasikan konteks dua arah

e_t : Skor relevansi dari hidden state h_t

a_t : Bobot perhatian (attention weight) untuk waktu ke- t

s : Vektor konteks hasil weighted sum dari hidden states

W_a, b_a : Bobot dan bias pada lapisan attention

T : Panjang sekuens input (jumlah langkah waktu)