

Peramalan Data Ekonomi Menggunakan Model *Hybrid Vector Autoregressive-Long Short Term Memory*

<http://dx.doi.org/10.28932/jutisi.v11i1.10066>

Riwayat Artikel

Received: 30 September 2024 | Final Revision: 08 April 2025 | Accepted: 08 April 2025

Creative Commons License 4.0 (CC BY – NC)



A. Gilang Aleyusta Savada^{✉#1}, Gigih Forda Nama^{#2}, Titin Yulianti^{#3}, Mardiana^{#4}

[#] Program Studi Teknik Informatika, Universitas Lampung

Jl. Prof. Dr. Sumantri Brojonegoro No. 1, Bandar Lampung, Lampung 35145, Indonesia

¹gilangale90@gmail.com

²gigih@eng.unila.ac.id

³titin.yulianti@eng.unila.ac.id

⁴mardiana@eng.unila.ac.id

✉Corresponding author: gilangale90@gmail.com

Abstrak — Fluktuasi pada harga saham serta nilai tukar Rupiah menimbulkan ketidakpastian bagi investor dalam pengambilan keputusan investasi. Salah satu upaya meminimalisasi risiko investasi adalah dengan melalui peramalan menggunakan metode yang handal. Model peramalan tradisional seperti *Vector Autoregressive* (VAR) efektif menangkap pola linier, namun kurang mampu mengakomodasi pola yang lebih kompleks. Di sisi lain, model *deep learning* modern seperti *Long Short Term Memory* (LSTM) mampu menangani pola yang dinamis (linear dan nonlinear), tetapi memiliki keterbatasan dalam memproses hubungan simultan antara variabel secara konsisten. Penelitian ini bertujuan mengembangkan model peramalan *Hybrid* dengan mengintegrasikan pendekatan VAR dan LSTM untuk memprediksi Indeks Harga Saham Gabungan (IHSG) dan Kurs Rupiah terhadap Dollar Amerika. Model *Hybrid* VAR-LSTM memanfaatkan keunggulan VAR untuk pola linier serta LSTM untuk pola nonlinier dalam data deret waktu multivariat. Dengan kerangka kerja OSEMN (*Obtain, Scrub, Explore, Model, iNterpret*), penelitian ini memastikan proses analisis dilakukan secara sistematis dan komprehensif. Data dari Januari 2004 hingga Desember 2023 digunakan untuk membangun model, sementara data dari Januari hingga Juli 2024 digunakan untuk validasi. Kinerja model dievaluasi menggunakan *Mean Absolute Error* (MAE) untuk mengukur tingkat kesalahan dalam prediksi. Hasil menunjukkan bahwa model *Hybrid* VAR-LSTM mampu meningkatkan akurasi prediksi dibandingkan dengan model VAR secara independen, ditunjukkan oleh penurunan MAE sebesar 42,72 poin pada prediksi IHSG dan 55,82 poin pada prediksi Kurs Rupiah.

Kata kunci— *Hybrid* VAR-LSTM; Indeks Harga Saham Gabungan; Kerangka Kerja OSEMN; Kurs Rupiah; Peramalan Deret Waktu.

Economic Data Forecasting Using Hybrid Vector Autoregressive-Long Short Term Memory Model

Abstract — Fluctuations in stock prices and the Rupiah exchange rate create uncertainty for investors in their investment decision-making. One approach to minimizing investment risk is through forecasting utilizing a reliable method. Traditional forecasting models, such as *Vector Autoregressive* (VAR), are effective in capturing linear patterns but struggle to accommodate more complex

patterns. On the other hand, modern deep learning models like Long Short Term Memory (LSTM) can handle dynamic patterns (both linear and nonlinear) but have limitations in consistently processing simultaneous relationships among variables. This research aims to develop a Hybrid forecasting model by integrating VAR and LSTM approaches to predict the Composite Stock Price Index (IHSG) and the Rupiah exchange rate against the US Dollar. The Hybrid VAR-LSTM model leverages the strengths of VAR for linear patterns and LSTM for nonlinear patterns in multivariate time series data. Using the OSEMN framework (Obtain, Scrub, Explore, Model, iNterpret), this study ensures a systematic and comprehensive analysis process. Data from January 2004 to December 2023 is used to build the model, while data from January to July 2024 is used for validation. The model's performance is evaluated using Mean Absolute Error (MAE) to measure the prediction error. The results indicate that the Hybrid VAR-LSTM model significantly improves prediction accuracy compared to the VAR model used independently, as evidenced by a reduction of 42.72 points in MAE for IHSG predictions and 55.82 points for Rupiah predictions.

Keywords— Composite Stock Price Index; Hybrid VAR-LSTM; OSEMN Framework; Rupiah Exchange Rate; Time Series Forecasting.

I. PENDAHULUAN

Perkembangan pasar modal di Indonesia menunjukkan pertumbuhan yang signifikan dan konsisten. Berdasarkan data statistik dari Kustodian Sentral Efek Indonesia (KSEI), per Desember 2023 jumlah investor pasar modal Indonesia mencapai 12,13 juta Single Investor Identification (SID), mengalami peningkatan sebesar 17,60 persen year to date (ytd) dibandingkan dengan 10,31 juta SID per Desember 2022 [1]. Pada prinsipnya, pasar modal sendiri merupakan sarana pembentuk modal serta akumulasi dana jangka panjang yang ditujukan untuk meningkatkan partisipasi masyarakat dalam mendukung pembiayaan pembangunan nasional [2]. Dengan begitu, peningkatan jumlah investor pasar modal Indonesia melalui tingginya minat masyarakat terhadap investasi sangat dapat berdampak positif terhadap pertumbuhan ekonomi nasional.

Bagi investor, pasar modal berfungsi sebagai alternatif berinvestasi dengan keuntungan dan sejumlah risiko. Investasi saham dapat menjadi opsi pilihan bagi para investor yang ingin berpartisipasi dalam pertumbuhan perusahaan hingga memperoleh keuntungan dari imbal hasil atau return [3]. Di Indonesia, terdapat Indeks Harga Saham Gabungan (IHSG) yang merupakan indikator kinerja pergerakan harga saham dari berbagai sektor di Bursa Efek Indonesia (BEI). Pergerakan IHSG sebagai salah satu pengukuran kesehatan ekonomi negara sekaligus landasan analisis statistik atas kondisi pasar saham. Kondisi pasar modal Indonesia yang mengalami peningkatan (bullish) atau mengalami penurunan (bearish) dapat terlihat dari fluktuasi harga yang tercatat pada IHSG [4].

Kemudian, saham sebagai produk perdagangan utama di pasar modal cenderung mengalami fluktuasi dan tidak stabil. Ketidakpastian pasar memaksa para investor untuk memantau dengan cermat informasi dari berbagai faktor yang berpengaruh terhadap harga saham, termasuk fundamental ekonomi makro yaitu kurs atau nilai tukar mata uang [5]. Kurs merupakan perbandingan antara mata uang suatu negara dengan mata uang negara lain yang mencerminkan banyaknya unit mata uang yang dibutuhkan untuk memperoleh satu unit mata uang lainnya. Tentu saja, fluktuasi Kurs Rupiah dapat berdampak terhadap keputusan investasi para investor di Indonesia. Jika Kurs Rupiah melemah, maka dapat mempengaruhi keputusan investor melakukan penjualan saham sebab kemungkinan terjadi penurunan keuntungan dari peningkatan biaya operasional perusahaan. Sebaliknya, jika Kurs Rupiah menguat, maka dapat mendorong investor melakukan pembelian saham karena anggapan kondisi ekonomi sedang cerah [6].

Proyeksi melalui peramalan atau forecasting pada pergerakan IHSG dan Kurs Rupiah dapat menjadi panduan kritis bagi investor dalam mengambil keputusan investasi berdasarkan strategi sesuai dengan prediksi pasar. Peramalan sendiri merupakan suatu teknik untuk memperkirakan harga masa depan dengan memperhatikan data masa lalu maupun data masa kini. Aspek penting dalam peramalan merupakan analisis deret waktu atau time series melalui pengamatan serta pemodelan terhadap pola, trend, dan variasi data beruntun pada interval waktu tertentu [7]. Sementara itu, berdasarkan jumlah variabel yang sedang diobservasi, metode peramalan deret waktu dapat digolongkan menjadi dua jenis, yaitu univariat dan multivariat. Metode peramalan univariat merupakan pendekatan yang hanya memiliki satu variabel pengamatan, sedangkan multivariat memiliki lebih dari satu variabel pengamatan yang saling mempengaruhi [8].

Sebanarnya, terdapat beberapa pendekatan klasik statistika konvensional yang dapat digunakan dalam melakukan peramalan data deret waktu, salah satunya Vector Autoregressive (VAR). Model VAR merupakan metode peramalan deret waktu multivariat yang sederhana tanpa harus membedakan variabel endogen (Y) dan variabel eksogen (X). Model VAR mengasumsikan hubungan antara variabel dengan cara yang simultan serta linear, sehingga memiliki kekurangan dalam menangkap kompleksitas hubungan nonlinear [9]. Tentunya penggunaan suatu model dalam peramalan perlu disesuaikan pada sifat serta hubungan antara variabel yang diharapkan [2]. Oleh karena itu, penggunaan model linear saja tidak cukup menggambarkan hubungan campuran dalam peramalan IHSG dan Kurs Rupiah yang berpola kompleks.

Saat ini peramalan tidak hanya mengandalkan metode statistika konvensional, tetapi dapat juga memanfaatkan teknik deep learning yang muncul akibat perkembangan signifikan Artificial Intelligence (AI), salah satunya yaitu penggunaan

model Long Short Term Memory (LSTM). Model LSTM merupakan pengembangan Recurrent Neural Network (RNN) yang mampu mengekstraksi informasi jangka panjang sehingga menjadikannya alat yang cukup kuat untuk meramalkan trend dan perubahan panjang pada data time series atau sequential [10]. Model LSTM dapat mempelajari data dengan komputasi fleksibel melalui peran beberapa gerbang yang mengatur memori pada setiap neuron. Berbeda dengan VAR, model LSTM mampu memodelkan data berpola nonlinier. Namun, diperlukan sejumlah data besar untuk mempelajari pola data yang kompleks sehingga penggunaan LSTM secara independen pada data terbatas tidak mampu bersamaan menangani pola linier dan nonlinier dengan baik [11].

Selanjutnya, terdapat suatu pendekatan peramalan deret waktu yang dikenal sebagai model Hybrid yaitu kombinasi beberapa model berbeda untuk meningkatkan performa dibandingkan model individual yang diterapkan terpisah [12]. Konsep dasar dari peramalan model Hybrid adalah kombinasi keunggulan serta saling melengkapi kelemahan masing-masing model untuk menangkap berbagai hubungan dalam kompleksitas data. Penelitian mengenai model peramalan Hybrid pertama kali dikenalkan oleh Zhang [13], yang menyelidiki efektivitas kombinasi model Autoregressive Integrated Moving Average (ARIMA) dan Artificial Neural Network (ANN) dalam memprediksi berbagai fenomena, seperti data kurs uang, bintik matahari, dan kejernihan air. Dalam penelitian tersebut, aspek linearitas ditangani oleh model ARIMA yang secara efektif dapat menangkap analisis komponen tren dan musiman dalam data. Sementara, model ANN dimanfaatkan karena kemampuannya dalam melakukan pembelajaran lebih adaptif berfokus pada pola nonlinear yang sering kali tidak dapat diakomodasi oleh model tradisional. Hasilnya menunjukkan bahwa model Hybrid ARIMA-ANN dapat memberikan akurasi prediksi lebih baik dibandingkan penggunaan ARIMA atau ANN secara terpisah.

Pendekatan hybrid sangat rasional dengan kenyataan bahwa satu model tunggal sering kali tidak mampu menangkap seluruh kompleksitas data deret waktu, khususnya ketika pola linear dan nonlinear muncul bersamaan. Apabila diperhatikan lebih lanjut, riwayat IHSG dan Kurs Rupiah merupakan representasi dari data multivariate time series yang berpola campuran, yaitu linear dan nonlinear. Dengan begitu, sebenarnya prediksi deret waktu multivariat pada data IHSG dan Kurs Rupiah dengan kombinasi model VAR serta LSTM dapat dikembangkan menjadi model Hybrid VAR-LSTM. Model VAR digunakan untuk menganalisis serta meramalkan data dalam konteks linear, sedangkan residual dari model VAR dikonfigurasi kembali oleh model LSTM guna mengekstraksi elemen nonlinear dalam analisis. Oleh karena itu, tujuan penelitian ini adalah untuk membangun model peramalan Hybrid VAR-LSTM yang menggabungkan pendekatan VAR (linear) dengan LSTM (nonlinear) guna menghasilkan akurasi yang presisi pada prediksi data IHSG dan Kurs Rupiah. Selain itu, penelitian juga bertujuan untuk menganalisis perbandingan kinerja menggunakan metrik evaluasi Mean Absolute Error (MAE) antara model Hybrid VAR-LSTM dengan model VAR individu berdasarkan langkah sistematis dalam OSEMN framework, meliputi proses Obtain, Scrub, Explore, Model, dan Interpret.

II. METODE PENELITIAN

A. Sumber Data

Penelitian dengan pendekatan model Hybrid VAR-LSTM dilakukan terhadap variabel Indeks Harga Saham Gabungan (IHSG) dan Kurs Rupiah terhadap Dollar Amerika dalam periode 1 Januari 2004 hingga 31 Juli 2024. Sumber data yang digunakan adalah nilai harian penutupan IHSG yang diambil dari portal *website* resmi Yahoo Finance dan nilai harian transaksi tengah Kurs Rupiah terhadap Dollar Amerika yang diperoleh dari portal *website* resmi Bank Indonesia (BI).

B. Vector Autoregressive (VAR)

Model *Vector Autoregressive* (VAR) merupakan pendekatan statistika klasik pada data deret waktu multivariat berdasarkan hubungan beberapa variabel endogen yang cenderung berkaitan menurut lokasi terdekat [14]. Dalam model VAR, setiap variabel diperlakukan sebagai fungsi dari nilai masa lalu variabel itu sendiri dengan variabel lain dalam sistem, sehingga memungkinkan adanya pemodelan interdependensi. Model VAR sendiri banyak digunakan dalam studi bidang ekonomi serta keuangan dalam melakukan prediksi dan analisis deret waktu multivariat. Adapun prasyarat penggunaan model VAR bahwa data harus dalam keadaan stasioner dengan persamaan model VAR(p) yaitu:

$$y_t = \alpha + \phi y_{t-1} + \phi y_{t-2} + \dots + \phi y_{t-p} + \varepsilon_t \quad (1)$$

dengan:

- y_t = Vektor berukuran $m \times 1$ berisi m variabel yang masuk dalam model VAR pada waktu t dan $t - i$, dimana $i = 1, 2, \dots, p$
- α = Vektor berukuran $m \times 1$ berisi konstanta
- ϕ_i = Matriks parameter variabel endogen berukuran $m \times m$ untuk setiap $i = 1, 2, \dots, p$
- ε_t = Vektor galat berukuran $m \times 1$

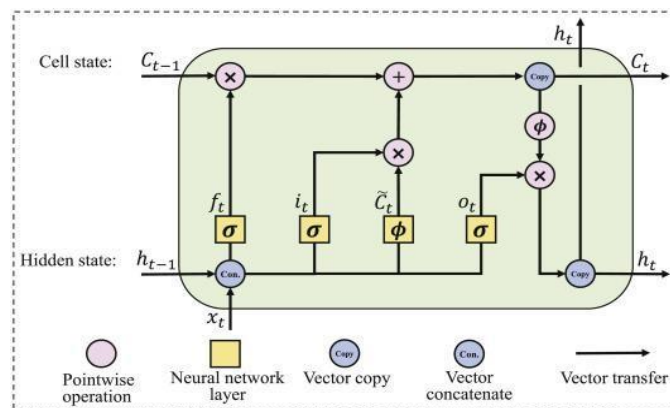
Model VAR(1) atau *Vector Autoregressive of order 1* merupakan bentuk khusus dari model VAR yang hanya menggunakan satu *lag* dari variabel-variabel dalam sistem. Pada model VAR(1), setiap variabel dijelaskan oleh nilai *lag* satu dari dirinya sendiri serta nilai *lag* satu dari variabel lainnya. Adapun VAR(1) yang terdiri dari 2 variabel y_1 dan y_2 dapat ditulis seperti persamaan (2) dan (3).

$$y_{1,t} = \alpha_1 + \phi_{11}y_{1,t-1} + \phi_{12}y_{2,t-1} + \varepsilon_{1,t} \quad (2)$$

$$y_{2,t} = \alpha_2 + \phi_{21}y_{1,t-1} + \phi_{22}y_{2,t-1} + \varepsilon_{2,t} \quad (3)$$

C. Long Short Term Memory (LSTM)

Model *Long Short Term Memory* (LSTM) merupakan jaringan saraf yang dirancang untuk memproses data berurutan dengan kemampuan mengingat informasi kompleks dalam jangka waktu panjang. Metode LSTM sangat baik digunakan dalam kasus penyelesaian masalah yang berkaitan dengan klasifikasi, pengolahan, dan prediksi data deret waktu. Struktur LSTM terdiri dari empat lapisan yang terhubung, yaitu tiga lapisan gerbang (*forget*, *input*, dan *output*) serta satu lapisan aktivasi tanh. Adapun arsitektur dari LSTM disajikan dalam Gambar 1.



Gambar 1. Arsitektur LSTM [15]

Forget gate berfungsi untuk mengontrol ketentuan penghapusan atau penambahan informasi dari setiap data masukan yang akan disimpan atau dihapus dalam *memory cell* menggunakan fungsi aktivasi *sigmoid*. Persamaan yang digunakan pada *forget gate* yaitu:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4) \text{ dengan:}$$

f_t = Vektor *output* dari *forget gate* pada waktu t
 σ = Fungsi aktivasi *sigmoid*
 h_{t-1} = *Hidden state* dari waktu sebelumnya
 x_t = Nilai *input* pada waktu t
 b = Nilai bias pada *gate*
 W = Matriks bobot pada *gate*

Input gate berfungsi untuk mengontrol informasi baru yang masuk ke dalam sel memori menggunakan fungsi aktivasi *sigmoid* dalam menentukan nilai yang diperbarui dan fungsi aktivasi *tanh* dalam menghasilkan nilai baru. Persamaan yang digunakan pada *input gate* yaitu:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5) \text{ dengan:}$$

i_t = Vektor *output* dari *input gate* pada waktu t

Cell gate berfungsi untuk mengontrol nilai pada sel memori sebelumnya agar digantikan oleh nilai sel memori baru dengan menggabungkan nilai-nilai dari *forget gate* dan *input gate*. Pada bagian ini, fungsi aktivasi *tanh* dipilih karena dapat menjaga keseimbangan nilai dengan rentang -1 hingga 1, sehingga membantu mempertahankan informasi lebih lama dan mengurangi risiko *vanishing gradient*. Kombinasinya dengan fungsi *sigmoid* pada *forget gate* membuat model lebih stabil dan efisien dalam peramalan data deret waktu seperti IHSG dan Kurs Rupiah. Persamaan yang digunakan pada *cell gate* yaitu:

$$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

dengan:

$$\begin{aligned} \hat{C}_t &= \text{Vektor kandidat cell state baru pada waktu } t \\ \tanh &= \text{Fungsi aktivasi tanh} \end{aligned}$$

Output gate berfungsi untuk mengontrol informasi dalam sel memori yang akan dikeluarkan melalui operasi pada lapisan *sigmoid* dan *tanh* sebelumnya. Persamaan yang digunakan pada *output gate* yaitu:

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = O_t \times \tanh(C_t) \quad (8)$$

dengan:

$$\begin{aligned} O_t &= \text{Vektor output dari output gate pada waktu } t \\ h_t &= \text{Cell state update pada waktu } t \end{aligned}$$

D. Hybrid VAR-LSTM

Model *Hybrid* merupakan pengembangan dengan konsep dasar kombinasi beberapa metode yang bertujuan untuk memberikan hasil lebih akurat dibanding model individual [12]. Dapat diasumsikan bahwa pada model deret waktu memiliki dua komponen dasar, yaitu linier dan nonlinier melalui persamaan (9) [13].

$$Y_t = L_t + N_t \quad (9)$$

dengan:

$$\begin{aligned} Y_t &= \text{Data pengamatan deret waktu ke-} t \\ L_t &= \text{Komponen linear ke-} t \\ N_t &= \text{Komponen nonlinear ke-} t \end{aligned}$$

Pada penelitian ini, model *Hybrid* VAR-LSTM melakukan pemisahan penanganan pola linier menggunakan VAR dan pola nonlinier menggunakan LSTM, sehingga mampu mengenali pola campuran dalam data multivariat. Model VAR digunakan terlebih dahulu untuk menangkap dan memprediksi komponen linier, serta menghasilkan residual sebagai bagian data yang tidak dapat ditangkap oleh model. Selanjutnya, residual digunakan sebagai *input* untuk model LSTM dapat menangkap dan memprediksi komponen nonlinier. Kombinasi kekuatan masing-masing model kemudian digunakan untuk membentuk prediksi akhir model *Hybrid* dengan menggabungkan prediksi komponen linier dan nonlinier melalui persamaan (10).

$$Y'_t = L'_t + N'_t \quad (10)$$

dengan:

$$\begin{aligned} Y'_t &= \text{Nilai peramalan dari model hybrid ke-} t \\ L'_t &= \text{Nilai peramalan dari komponen linear ke-} t \\ N'_t &= \text{Nilai peramalan dari komponen nonlinear ke-} t \end{aligned}$$

E. Evaluasi Mean Absolute Error (MAE)

Mean Absolute Error (MAE) merupakan salah satu matriks evaluasi yang dapat digunakan untuk mengukur akurasi dari model yang melakukan prediksi. Besaran MAE menghitung rata-rata dari selisih absolut antara nilai aktual yang terobservasi dengan nilai prediksi model. Dalam analisis *forecasting*, MAE memberikan gambaran mengenai seberapa besar kesalahan rata-rata model dalam satuan yang sama dengan data aktual. Metrik MAE mudah diinterpretasikan karena memberikan informasi langsung tentang rata-rata deviasi antara hasil prediksi dan nilai nyata tanpa melihat arah kesalahan (*overestimation* atau *underestimation*). Nilai MAE yang lebih rendah menunjukkan bahwa model *forecasting* memiliki kemampuan prediksi lebih akurat, sehingga dapat diandalkan dalam pengambilan keputusan berbasis data. Adapun persamaan MAE yaitu:

$$MAE = \frac{1}{n} \sum_{i=1}^t |Z_t - \hat{Z}_t| \quad (11)$$

dengan:

$$\begin{aligned} t &= \text{Banyak data pengamatan} \\ Z_t &= \text{Data pengamatan ke-} t \\ \hat{Z}_t &= \text{Nilai duga dari data pengamatan ke-} t \end{aligned}$$

F. Kerangka Kerja OSEMNI

OSEMNI merupakan *framework* atau kerangka kerja sistematis dalam bidang ilmu data yang populer untuk mengorganisir dan mengarahkan proses pengolahan data dari awal hingga akhir. Kerangka kerja OSEMNI memungkinkan melakukan analisis komprehensif dengan kemudahan dapat kembali ke langkah tertentu dari pemrosesan data yang terdiri dari tahapan berupa *Obtain*, *Scrub*, *Explore*, *Model*, *Interpret* [16]. Dalam penelitian ini, data pada tahap *Obtain* diunduh dari *website* dan disimpan menggunakan Microsoft Excel untuk mengorganisir fase awal data. Selanjutnya, analisis lebih lanjut dari tahap *Explore* hingga *Interpret* dilakukan menggunakan Python di Google Colab. Adapun tahapan sistematis dari kerangka kerja OSEMNI disajikan dalam Gambar 2.



Gambar 2. Tahapan Kerangka Kerja OSEMNI [17]

- 1) *Obtain*: Pada tahap ini, dilakukan pengumpulan data harian Indeks Harga Saham Gabungan (IHSG) serta Kurs Rupiah terhadap Dollar Amerika yang diunduh secara terpisah menjadi dua format CSV dalam periode 1 Januari 2004 – 31 Juli 2024.
- 2) *Scrub*: Pada tahap ini, *dataset* IHSG serta Kurs Rupiah yang sebelumnya didapatkan akan melewati proses seleksi fitur sesuai tujuan, penghapusan *missing value*, pengubahan laporan harian menjadi bulanan (*resampling data*), penggabungan dari satu *dataset* menjadi satu *dataframe* tunggal, dan pembagian *dataset* (*time series split*). Adapun fitur yang digunakan pada *dataset* IHSG berupa nilai penutupan harian yang terdiri atas 5093 baris data serta dua kolom, yaitu 'Date' dan 'Close'. Sementara itu, pada *dataset* Kurs Rupiah akan memakai fitur nilai harian kurs tengah antara Rupiah dan Dollar Amerika yang terdiri atas 5038 baris data serta dua kolom, yaitu 'Date' dan 'Kurs Dollar'. Kemudian, dilakukan penghapusan *missing value* dilanjutkan dengan mengubah data harian menjadi bulanan menggunakan teknik *resampling data* berdasarkan *mean* atau rata-rata yang mewakili data dalam satu bulan tertentu. Dengan begitu, data harian yang awalnya berjumlah besar dapat diringkas menjadi data bulanan yang lebih mudah diramalkan. Selanjutnya, kedua *dataset* yang sebelumnya terpisah digabungkan menjadi satu *dataset* tunggal berisi nilai rata-rata per bulan dari *Close* IHSG dan Kurs Dollar (USD/ IDR) berdasarkan tanggal sebagai indeks. Pada tahap akhir, *dataset* dibagi menjadi 240 baris data awal mencakup periode Januari 2004 hingga Desember 2023 sebagai *training* (*data in-sample*) untuk membangun model. Sementara itu, 7 baris data terakhir mencakup periode Januari 2024 hingga Juli 2024 sebagai *testing* (*data out-sample*) untuk memvalidasi performa model dalam melakukan peramalan.
- 3) *Explore*: Pada tahap ini, dilakukan eksplorasi atau analisis dari *data in-sample* sebagai data *training* yang digunakan untuk membangun model. Tujuannya agar dapat memberikan wawasan dalam melakukan analisis peramalan lebih lanjut. Adapun langkah-langkah yang dilakukan berupa visualisasi *plot time series* dan uji stasioneritas dengan *Augmented Dickey- Fuller*.
- 4) *Model*: Pada tahap ini, dilakukan pemodelan algoritma peramalan berdasarkan data yang telah dieksplorasi. Sebelum melakukan pemodelan *Hybrid*, pertama dilakukan pemodelan *Vector Autoregressive* menggunakan data *training* melalui langkah berikut:
 - a. Memilih *lag order optimum* menggunakan *Akaike Information Criterion* (AIC).
 - b. Membangun model berdasarkan *lag order optimum* dengan estimasi parameter menggunakan metode kuadrat terkecil atau *Ordinary Least Squares* (OLS).Tahap berikutnya adalah mengembangkan model *Hybrid* dengan memanfaatkan residual dari model VAR yang sebelumnya telah dibangun. Adapun langkah membangun model *Hybrid VAR-LSTM* adalah seperti berikut:
 - a. Membangun model *LSTM* menggunakan residual dari model VAR.
 - b. Mendapatkan hasil *forecasting* residual dari model *LSTM*.
 - c. Menjumlahkan hasil *forecasting* model VAR dengan *forecasting* residual model *LSTM* sehingga menjadi hasil peramalan akhir *Hybrid VAR-LSTM*.
- 5) *Interpret*: Pada tahap ini, dilakukan interpretasi hasil dari seluruh model yang telah dibangun, yaitu model VAR dan model *Hybrid VAR-LSTM*. Proses interpretasi model VAR dilakukan dengan mengidentifikasi estimasi model VAR

terbaik yang memungkinkan untuk dapat dipadukan dalam model Hybrid VAR-LSTM. Setelah menemukan model optimal, residual dari model VAR digunakan untuk pemodelan Hybrid VAR-LSTM. Kemudian pada tahap interpretasi model Hybrid, hasil peramalan akhir dievaluasi untuk melihat perbandingan MAE dari model Hybrid dan VAR secara independen. Selain itu, diberikan juga perbandingan visualisasi grafik hasil peramalan dari model Hybrid dan VAR individual.

III. HASIL DAN PEMBAHASAN

A. Obtain dan Scrub

Adapun bentuk data mentah (*raw data*) nilai harian IHSG yang diunduh langsung dari *website* Yahoo Finance dalam format CSV disajikan dalam Tabel 1.

TABEL 1
DATASET IHSG (SUMBER: YAHOO FINANCE [18])

| | Date | Open | High | Low | Close | Adj Close | Volume |
|------|------------|---------|---------|---------|--------|-----------|--------------|
| 1 | 02/01/2004 | 691,38 | 704,50 | 688,00 | 704,50 | 704,47 | 11244500,00 |
| 2 | 05/01/2004 | 706,37 | 725,47 | 706,37 | 725,47 | 725,44 | 35915500,00 |
| 3 | 06/01/2004 | 728,72 | 738,16 | 717,83 | 723,99 | 723,96 | 39797000,00 |
| 4 | 07/01/2004 | 723,91 | 723,92 | 705,84 | 709,37 | 709,34 | 33583800,00 |
| 5 | 08/01/2004 | 709,36 | 730,82 | 709,36 | 730,82 | 730,79 | 31361400,00 |
| ... | ... | ... | ... | ... | ... | ... | ... |
| 5093 | 30/07/2024 | 7283,92 | 7292,56 | 7226,78 | 7241,6 | 7241,86 | 124088300,00 |

Sementara itu, bentuk data mentah (*raw data*) besaran harian Kurs Rupiah terhadap Dollar Amerika yang diunduh langsung dari *website* Bank Indonesia dalam format CSV disajikan dalam Tabel 2.

TABEL 2
DATASET KURS RUPIAH (SUMBER: BANK INDONESIA [19])

| | Date | Kurs Dollar |
|------|------------|-------------|
| 1 | 31/07/2024 | 16320,00 |
| 2 | 30/07/2024 | 16286,00 |
| 3 | 29/07/2024 | 16294,00 |
| 4 | 26/07/2024 | 16268,00 |
| 5 | 25/07/2024 | 16224,00 |
| ... | ... | ... |
| 5038 | 01/01/2004 | 8574,00 |


Sebelum melakukan analisis menggunakan metode *forecasting*, *dataset* IHSG pada Tabel 1 dan *dataset* Kurs Rupiah pada Tabel 2 akan melewati beberapa proses, yaitu seleksi fitur sesuai tujuan, penghapusan *missing value*, pengubahan laporan harian menjadi bulanan (*resampling data*), penggabungan dari dua *dataset* menjadi satu *dataframe* tunggal, dan pembagian *dataset* (*time series split*). Adapun bentuk dataset akhir akan berjumlah 247 baris sesuai jumlah bulan dari Januari 2004 sampai Juli 2024 dengan indeks berformat bulan dan tahun. Terdiri atas kolom 'Close' sebagai nilai penutupan IHSG dan kolom 'Kurs Dollar' sebagai nilai transaksi tengah kurs Rupiah terhadap Dollar Amerika. Dari *dataset* ini, 240 baris pertama (Januari 2004 hingga Desember 2023) digunakan sebagai data pelatihan (*in-sample*), sementara 7 baris terakhir (Januari 2024 hingga Juli 2024) digunakan sebagai data validasi (*out-sample*) untuk melihat performa model ketika peramalan. Struktur data yang bersih serta siap digunakan untuk analisis deret waktu lebih lanjut disajikan dalam Tabel 3.

TABEL 3
DATASET FINAL

| Date | Close | Kurs Dollar |
|----------------------|---------|-------------|
| Jan 2004 | 753,23 | 8394,95 |
| Feb 2004 | 767,55 | 8425,17 |
| Mar 2004 | 745,39 | 8568,82 |
| Apr 2004 | 787,20 | 8608,25 |
| May 2004 | 726,21 | 8965,32 |
| ... | ... | ... |
| Mar 2024 | 7339,20 | 15702,61 |
| Apr 2024 | 7165,03 | 16100,00 |
| May 2024 | 7154,31 | 16083,94 |
| Jun 2024 | 6904,72 | 16329,39 |
| Jul 2024 | 7257,83 | 16261,65 |
| 247 rows × 2 columns | | |

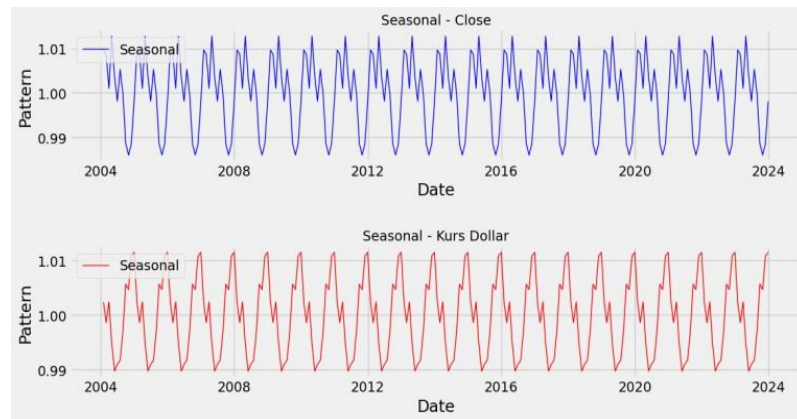
B. Explore

Eksplorasi data adalah tahap penting dalam analisis yang bertujuan memahami karakteristik serta tindakan penanganan variabilitas dalam *dataset*. Adapun *plot trend* data awal *Close* dan *Kurs Dollar* disajikan dalam Gambar 3.



Gambar 3. Grafik Tren *Close* IHSN dan Kurs Rupiah (USD/ IDR)

Berdasarkan Gambar 3, grafik tren *Close* IHSN dan Kurs Dollar (USD/ IDR) menunjukkan adanya dinamika pasar yang saling mempengaruhi antara IHSN dan Kurs Rupiah. Dalam jangka panjang, kedua variabel menunjukkan tren positif dengan peningkatan yang konsisten dan moderat. Hal ini mencerminkan pertumbuhan ekonomi yang stabil meskipun ada fluktuasi dalam kedua variabel. Namun, dalam jangka pendek, kedua variabel sering mengalami fluktuasi negatif yang disebabkan oleh ketidakpastian pasar dan faktor eksternal. Kenaikan Kurs Dollar sering berdampak negatif pada IHSN karena investor cenderung menjual saham akibat kekhawatiran ekonomi. Misalnya, selama krisis ekonomi tahun 2008 serta pandemi Covid-19 tahun 2020, terjadi pelemahan Rupiah disertai dengan penurunan IHSN akibat aksi jual besar-besaran serta meningkatnya permintaan terhadap Dollar US sebagai aset *safe haven*. Adapun *plot seasonal* data awal *Close* dan Kurs Dollar disajikan dalam Gambar 4.




Gambar 4. Grafik *Seasonal Close* IHSG dan Kurs Dollar (USD/ IDR)

Berdasarkan Gambar 4, grafik musiman atau *seasonal Close* IHSG dan Kurs Dollar (USD/ IDR) menunjukkan adanya pola musiman yang berulang setiap tahun. Pada grafik *seasonal Close* IHSG, terlihat adanya fluktuasi tahunan yang terjadi di pasar saham Indonesia, seperti kenaikan di awal tahun mencerminkan sentimen positif serta penurunan di pertengahan tahun akibat koreksi pasar. Sementara itu, pola musiman pada Kurs Dollar (USD/IDR) menunjukkan pergerakan yang menyesuaikan dengan kondisi ekonomi nasional serta global, seperti depresiasi Rupiah akhir tahun dan apresiasi awal tahun. Sementara itu, hasil uji Augmented Dickey Fuller untuk menentukan langkah *differencing data* setiap variabelnya disajikan dalam Tabel 4.

TABEL 4
HASIL UJI AUGMENTED DICKEY FULLER

| Kondisi | Variabel | Test Statistic | p-Value | Critical Value (5%) | Status |
|-------------------------|-------------|----------------|------------------------|---------------------|---------------|
| Sebelum Differencing | Close | -0,95 | 0,76 | -2,87 | Non Stasioner |
| | Kurs Dollar | -0,71 | 0,84 | -2,87 | Non Stasioner |
| Setelah 1x Differencing | Close | -5,38 | $3,63 \times 10^{-6}$ | -2,87 | Stasioner |
| | Kurs Dollar | -8,5 | $1,18 \times 10^{-13}$ | -2,87 | Stasioner |

Berdasarkan Tabel 4, hasil uji *Augmented Dickey Fuller* menunjukkan bahwa kedua variabel tidak stasioner. Terlihat dari *p-value Close* sebesar 0,76 serta Kurs Dollar sebesar 0,84 yang lebih besar dari tingkat signifikansi 5%, sehingga perlu dilakukan tindakan *differencing* agar data stasioner dengan cara mengurangi nilai dari suatu titik data dengan nilai titik data sebelumnya. Setelah dilakukan *differencing* satu kali, kedua variabel menjadi stasioner dengan *p-value Close* sebesar $3,63 \times 10^{-6}$ serta Kurs Dollar sebesar $1,18 \times 10^{-13}$, jauh lebih kecil dari tingkat signifikansi 5%. Dengan demikian, data tersebut menjadi stasioner dengan *mean* dan *varians* yang konstan sehingga memenuhi prasyarat analisis dan peramalan menggunakan berbagai metode statistik, termasuk model VAR untuk *forecasting*. Adapun *plot* data *Close* dan Kurs Dollar setelah dilakukan *differencing* disajikan dalam Gambar 5.



Gambar 5. *Plot* Data Stasioner Setelah *First Differencing*


C. Model dan Interpret

1) *Pemodelan dan Interpretasi Model VAR*: Langkah pertama dalam eksperimen untuk menangkap pola linear pada data menggunakan model VAR adalah dengan menentukan urutan *lag* yang optimal melalui analisis *Akaike Information Criterion* (AIC). Besaran AIC yang paling rendah menunjukkan model terbaik dalam menyesuaikan antara kompleksitas model dan ketersediaan data. Pemilihan *lag order optimal* sangat penting dalam analisis *time series* karena secara langsung dapat mempengaruhi akurasi prediksi dan interpretasi hubungan antara variabel. Adapun hasil hitung AIC yang telah dilakukan pada variabel Close IHSG dan Kurs Dollar (USD/ IDR) disajikan dalam Tabel 5.


TABEL 5
HASIL HITUNG AIC BERBAGAI LAG

| Lag Uji Coba | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
|--------------|-------|-------|-------|--------|-------|-------|-------|-------|-------|-------|-------|
| Nilai AIC | 21,13 | 21,06 | 20,99 | 20,97* | 20,99 | 21,01 | 21,00 | 21,02 | 21,01 | 21,01 | 21,00 |

Berdasarkan Tabel 5, setelah dilakukan uji coba sebanyak 10 *lag* didapatkan bahwa *lag order* 3 memiliki nilai AIC paling rendah sebesar 20,97. Dengan begitu, *lag order* 3 akan digunakan dalam membangun model VAR dan mendapatkan residual. Penggunaan *lag order* 3 berarti bahwa model melakukan prediksi nilai menggunakan informasi dari 3 periode sebelumnya. Adapun grafik visualisasi hasil *fitting* model VAR pada data *training* menggunakan *lag order* 3 dengan estimasi parameter melalui metode OLS disajikan dalam Gambar 6 dan Gambar 7.



Gambar 6. Fitted Model VAR (Close) – Data Training



Gambar 7. Fitted Model VAR (Kurs Dollar) – Data Training

Gambar 6 (Close) dan Gambar 7 (Kurs Dollar) merupakan perbandingan plot visualisasi antara data aktual (garis biru) dan prediksi (garis merah) yang dihasilkan oleh *fitting* model VAR menggunakan data *training* dari Januari 2004 sampai Desember 2023. Terlihat bahwa model VAR cukup efektif dalam menangkap tren umum, tetapi kurang responsif terhadap fluktuasi dinamis. Variabilitas jangka pendek serta faktor volatilitas yang sering kali sulit diprediksi oleh model VAR menyebabkan deviasi *error* MAE yang cukup signifikan, yaitu *Close* sebesar 373,34 dan *Kurs Dollar* sebesar 702,70.

Karakteristik linier dari model VAR sendiri membuatnya kurang mampu merespons pola fluktuasi yang lebih kompleks, sehingga mengakibatkan ketidakakuratan dalam prediksi saat kondisi pasar bergejolak. Hal ini menyoroti bahwa penggunaan model VAR secara independen (linear) tidak mampu menghasilkan prediksi yang akurat pada data berpola campuran, yaitu linear dan nonlinear. Oleh karenanya, perlu dilakukan pengembangan model yang lebih adaptif serta fleksibel dalam menangani jenis data bervolatilitas cukup tinggi. Adapun hasil *forecasting Close IHSG* dan *Kurs Rupiah (USD/ IDR)* setara data *testing (7 steps ahead)*, terhitung dari bulan Januari 2024 sampai Juli 2024 disajikan dalam Tabel 6.

TABEL 6
HASIL FORECASTING MODEL VAR

| Date | L_t' | |
|----------|---------|-------------|
| | Close | Kurs Dollar |
| Jan 2024 | 7269,05 | 15535,73 |
| Feb 2024 | 7318,74 | 15561,97 |
| Mar 2024 | 7329,97 | 15599,68 |
| Apr 2024 | 7344,44 | 15647,70 |
| May 2024 | 7365,40 | 15684,61 |
| Jun 2024 | 7392,62 | 15710,49 |
| Jul 2024 | 7421,29 | 15738,08 |

Berdasarkan Tabel 6, peramalan dilakukan sebanyak 7 langkah ke depan sesuai dengan jumlah ketersediaan data pengujian. *Forecasting* dilakukan menggunakan model VAR yang sudah diestimasi pada tahap sebelumnya dengan data *training* sebagai data historis. Sementara itu, pada tahap selanjutnya residual atau sisa hitung yang tidak dapat ditangkap oleh model selama proses *fitting* model VAR akan digunakan sebagai input data untuk melatih algoritma LSTM pada model *Hybrid*.

2) *Pemodelan dan Interpretasi Model Hybrid*: Pada bagian ini, data residual dari estimasi terbaik model VAR yang sebelumnya sudah didapatkan akan dimodelkan menggunakan LSTM untuk menghasilkan prediksi nonlinear. Kemudian, hasil peramalan menggunakan model VAR (linear) dan peramalan residual menggunakan model LSTM (nonlinear) akan digabungkan untuk membentuk peramalan akhir model *Hybrid* VAR-LSTM. Dalam pemodelan *Hybrid*, digunakan dua model LSTM *univariate* yang terpisah untuk meramalkan data residual masing-masing variabel. Model LSTM pertama dilatih menggunakan data residual *Close IHSG* tanpa melibatkan komponen *Kurs Dollar*. Sebaliknya, model LSTM kedua dilatih menggunakan data residual *Kurs Dollar (USD/ IDR)* tanpa melibatkan komponen *Close IHSG*. Tujuannya agar setiap model LSTM dapat menangkap pola komprehensif masing-masing variabel dengan membagi kompleksitas data menjadi dua bagian sesuai jumlah variabel pengamatan. Pembentukan LSTM sendiri meliputi proses normalisasi data, *splitting* data, definisi arsitektur model, *hyperparameter* dengan *grid search*, pelatihan, dan evaluasi. Adapun arsitektur model dengan *parameters* terbaik pada masing-masing variabel disajikan dalam Tabel 7.

TABEL 7
PARAMETERS MODEL LSTM TERBAIK

| Parameters | Close | Kurs Dollar |
|-----------------------|-------|-------------|
| <i>Time Steps</i> | 15 | 15 |
| <i>Splitting Data</i> | 80/20 | 80/20 |
| <i>Units 1 LSTM</i> | 50 | 100 |
| <i>Units 2 LSTM</i> | 50 | 100 |
| <i>Drop Out Rate</i> | 0,3 | 0,2 |
| <i>Learning Rate</i> | 0,01 | 0,01 |
| <i>Batch Size</i> | 32 | 32 |
| <i>Epochs</i> | 50 | 50 |

Berdasarkan Tabel 7, arsitektur model LSTM tersusun atas beberapa komponen utama yang dirancang untuk menangani data sekuensial dengan dependensi jangka panjang. Proses terdiri dari 2 lapisan LSTM yang disertai penggunaan *dropout* pada setiap lapisannya untuk mengurangi risiko *overfitting*. Di akhir, lapisan *dense* dengan satu neuron dan aktivasi linear digunakan untuk menghasilkan *output* tunggal. Model dikompilasi menggunakan *optimizer Adam* dengan *learning rate* serta fungsi *loss* dalam mengoptimalkan proses pembelajaran. Dalam penerapannya, digunakan timesteps berjumlah 15

yang berarti model memperhitungkan setiap 15 nilai pada waktu sebelumnya untuk memprediksi setiap 1 langkah mendatang. Sementara itu, evaluasi dilakukan dengan melihat kurva *loss* serta grafik *validation* menggunakan 20% data testing residual untuk memastikan model cukup handal dalam melakukan *forecasting* pada data baru. Adapun hasil akhir model *Hybrid* dari penggabungan *forecasting* model VAR dengan *forecasting* residual model LSTM disajikan dalam Tabel 8.

TABEL 8
HASIL FORECASTING MODEL HYBRID

| Date | L_t' | | N_t' | | $L_t' + N_t'$ | |
|----------|---------|-------------|---------|-------------|---------------|-------------|
| | Close | Kurs Dollar | Close | Kurs Dollar | Close | Kurs Dollar |
| Jan 2024 | 7269,05 | 15535,73 | -89,83 | 84,34 | 7179,22 | 15742,16 |
| Feb 2024 | 7318,74 | 15561,97 | -61,33 | 41,63 | 7257,41 | 15751,23 |
| Mar 2024 | 7329,97 | 15599,68 | -58,93 | 21,71 | 7271,04 | 15755,43 |
| Apr 2024 | 7344,44 | 15647,70 | -68,63 | 11,70 | 7275,81 | 15774,28 |
| May 2024 | 7365,40 | 15684,61 | -84,25 | 6,89 | 7281,15 | 15789,50 |
| Jun 2024 | 7392,62 | 15710,49 | -102,69 | 5,43 | 7289,94 | 15794,96 |
| Jul 2024 | 7421,29 | 15738,08 | -122,41 | 5,98 | 7298,88 | 15801,59 |

3) *Evaluasi Model*: Perbandingan model *Hybrid* dan VAR individual dilakukan dengan mengamati nilai MAE serta visualisasi grafik prediksi berdasarkan data validasi dari Januari 2024 hingga Juli 2024. Hasil evaluasi dari setiap metode disajikan dalam Tabel 9 berikut.


TABEL 9
PERBANDINGAN PERFORMA MODEL *HYBRID* DAN VAR INDEPENDEN

| Date | Close | | | Kurs Dollar | | |
|-------------|---------------|---------------|---------|---------------|---------------|----------|
| | VAR | Hybrid | Aktual | VAR | Hybrid | Aktual |
| Jan 2024 | 7269,05 | 7179,22 | 7238,07 | 15535,73 | 15742,16 | 15610,82 |
| Feb 2024 | 7318,74 | 7257,41 | 7284,16 | 15561,97 | 15751,23 | 15665,33 |
| Mar 2024 | 7329,97 | 7271,04 | 7339,20 | 15599,68 | 15755,43 | 15702,61 |
| Apr 2024 | 7344,44 | 7275,81 | 7165,03 | 15647,70 | 15774,28 | 16100,00 |
| May 2024 | 7365,40 | 7281,15 | 7154,31 | 15684,61 | 15789,50 | 16083,94 |
| Jun 2024 | 7392,62 | 7289,94 | 6904,72 | 15710,49 | 15794,96 | 16329,39 |
| Jul 2024 | 7421,29 | 7298,88 | 7257,83 | 15738,08 | 15801,59 | 16261,65 |
| MAE | 159,52 | 116,80 | - | 325,06 | 269,24 | - |
| MAPE | 2,20% | 1,61% | - | 2,08% | 1,73% | - |


Pada penelitian ini, MAE digunakan sebagai metrik evaluasi karena kemampuannya mengukur rata-rata selisih absolut antara nilai aktual dan prediksi dalam satuan asli data, sehingga lebih mudah diinterpretasikan secara langsung dalam konteks peramalan IHSG dan Kurs Rupiah. Berdasarkan Tabel 9, model *Hybrid* VAR-LSTM menunjukkan kinerja lebih unggul dibandingkan model VAR individu. Hal ini terlihat dari nilai MAE yang lebih rendah ketika peramalan masing-masing variabel, yaitu *Close* IHSG dan Kurs Dollar (USD/ IDR). Tercatat MAE pada variabel *Close* untuk model VAR sebesar 159,52 sementara model *Hybrid* VAR sebesar 116,80, menurun selisih 42,72 poin. Kemudian pada variabel Kurs Dollar, tercatat MAE untuk model VAR sebesar 325,06, sementara model *Hybrid* VAR-LSTM sebesar 269,24, menurun selisih 55,82 poin. Nilai MAE yang lebih rendah pada model *Hybrid* menunjukkan bahwa model mampu menangkap pola lebih baik dan menghasilkan prediksi lebih akurat.

Dalam prinsipnya, model VAR merupakan suatu pendekatan peramalan yang memiliki keterbatasan karena hanya dapat menangkap hubungan linear saja. Model VAR lebih efektif digunakan pada data dengan pola relatif sederhana dan memiliki hubungan linear yang stabil. Sementara itu, model LSTM memiliki kemampuan menangkap pola campuran (linear dan nonlinear) dalam data *time series* yang kompleks. Namun, model LSTM akan mengalami kesulitan mempertahankan konsistensinya memproses hubungan simultan antara variabel dengan pola dinamis (linear dan nonlinear) secara bersamaan sepanjang periode pengamatan. Sementara itu, model *Hybrid* VAR-LSTM merupakan pendekatan yang

mengkombinasikan keunggulan VAR dalam menangkap hubungan linear dengan keunggulan LSTM dalam mengidentifikasi pola nonlinear dalam data *time series*. Integrasi tersebut memungkinkan model *Hybrid* dapat lebih adaptif terhadap perubahan dinamis dalam kompleksitas data, sehingga memberikan hasil *forecasting* yang handal dan *robust*, bahkan dalam kondisi pasar volatil. Adapun grafik visualisasi hasil *forecasting* dari berbagai model yang dipakai disajikan dalam Gambar 8 dan Gambar 9.



Gambar 8. Grafik Visualisasi Perbandingan Hasil *Forecasting* pada Variabel *Close*



Gambar 9. Grafik Visualisasi Perbandingan Hasil *Forecasting* pada Variabel Kurs Dollar

Berdasarkan Gambar 8 dan Gambar 9, terlihat bahwa model *Hybrid* VAR-LSTM (garis ungu) menghasilkan prediksi lebih mendekati garis aktual (garis hijau) dibandingkan dengan model VAR (garis oranye) pada dua variabel yang diobservasi, yaitu *Close* IHSG dan Kurs Rupiah (USD/ IDR). Dengan interval kepercayaan (*confidence interval*, CI) dari MAE dalam tingkat 95% yang juga lebih sempit pada model *hybrid* membuktikan bahwa model prediksi lebih handal dibandingkan model VAR. Untuk *Close* IHSG, model VAR memiliki CI MAE 95% sebesar 159.52 ± 153.18 , sedangkan *Hybrid* VAR-LSTM lebih baik dengan 116.81 ± 114.38 . Untuk Kurs Dollar, VAR memiliki CI MAE 95% sebesar 325.07 ± 209.66 , sedangkan *Hybrid* VAR-LSTM lebih baik dengan 269.24 ± 172.99 . Kemudian, meskipun model *Hybrid* VAR-LSTM lebih unggul dibandingkan VAR, tetap terjadi penurunan akurasi seiring bertambahnya periode peramalan, terutama pada poin ke-4 dan seterusnya. Hal tersebut terjadi karena IHSG serta Kurs Rupiah sangat dipengaruhi oleh berbagai faktor eksternal seperti kebijakan moneter, suku bunga, inflasi, sentimen pasar, dan situasi global. Sementara itu, model *forecasting* hanya mengandalkan data historis tanpa mempertimbangkan faktor eksternal, sehingga akhirnya model gagal mengantisipasi ketika terjadi perubahan mendadak akibat kompleksitas berbagai faktor eksternal tersebut.

IV. SIMPULAN

Kesimpulan dari penelitian ini menegaskan bahwa model *Hybrid* VAR-LSTM menawarkan keunggulan dari kombinasi prinsip linear (VAR) dan nonlinear (LSTM) dalam melakukan *forecasting* pada data *time series multivariate* yang berfluktuasi tinggi, seperti data Indeks Harga Saham Gabungan (IHSG) dan Kurs Rupiah terhadap Dollar Amerika.

Fluktuasi tinggi tersebut karena pengaruh berbagai faktor, seperti dinamika pasar global, kebijakan moneter, serta sentimen investor yang berubah secara cepat. Faktor eksternal seperti suku bunga, inflasi, serta krisis ekonomi global turut menyebabkan pola pergerakan yang tidak stabil dan sulit diprediksi. Selain itu, hubungan *multivariate* antara variabel ekonomi, sifat non-stasioner data, serta efek spekulatif di pasar keuangan menambah kompleksitas dalam peramalan. Oleh karena itu, analisis *time series multivariate* pada kedua variabel memerlukan model yang mampu menangkap pola nonlinear dan dinamis untuk menghasilkan prediksi yang lebih akurat.

Adapun hasil penelitian menunjukkan bahwa terjadi penurunan MAE pada model *Hybrid VAR-LSTM* dibandingkan penggunaan model VAR independen, dengan selisih MAE pada IHSG sebesar 42,72 poin dan Kurs Rupiah sebesar 55,82. Dalam kenyataannya, model VAR menghasilkan prediksi yang cenderung linear dengan pola garis prediksi lurus karena kurang fleksibel untuk menangkap perubahan dinamis dalam kompleksitas data. Sementara itu, model *hybrid* berhasil menangkap perubahan pada kompleksitas data berpola campuran, yaitu linear dan nonlinear dengan lebih halus. Dalam kasus analisis *time series multivariate* antara variabel IHSG dan Kurs Rupiah, model *Hybrid VAR-LSTM* mampu menghasilkan prediksi lebih presisi daripada model VAR secara independen.

Pada penelitian lebih lanjut disarankan agar melakukan pemahaman lebih mendalam mengenai hubungan yang sebenarnya terjadi serta berkontribusi signifikan terhadap fluktuasi IHSG dan Kurs Rupiah. Kemudian, disarankan meningkatkan pemanfaatan model dengan merancang aplikasi praktis prediksi *real-time* yang memberikan akses langsung kepada pengguna akhir dalam mendapatkan informasi penunjang keputusan berdasarkan model yang telah dikembangkan.

UCAPAN TERIMA KASIH

Rasa syukur yang mendalam dihaturkan kepada Tuhan Yang Maha Esa atas berkah dan rahmat-Nya, sehingga penelitian ini dapat diselesaikan dengan baik dan tepat waktu. Ucapan terima kasih juga disampaikan kepada semua pihak yang telah memberikan arahan, dukungan, dan bimbingan selama proses penelitian serta penulisan makalah jurnal.

DAFTAR PUSTAKA

- [1] K. S. E. I. (KSEI), "Statistik Pasar Modal Indonesia Desember 2023," 2023. https://www.ksei.co.id/files/Statistik_Publik_Desember_2023_v3.pdf (accessed Aug. 01, 2024).
- [2] R. N. Putri and S. Setiawan, "Peramalan Indeks Harga Saham Perusahaan Finansial LQ45 Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA) dan Vector Autoregressive (VAR)," *J. Sains dan Seni ITS*, vol. 4, no. 2, 2016.
- [3] N. P. A. K. Almira and N. L. P. Wiagustini, "Return on Asset, Return on Equity, dan Earning per Share Berpengaruh terhadap Return Saham," *E-Jurnal Manaj.*, vol. 9, no. 3, pp. 1069–1088, 2020.
- [4] E. Hartayu and R. A. S. Paramita, "Pengaruh Indikator Makroekonomi, Harga Minyak Dunia Dan Indeks Bursa Asia Terhadap IHSG Periode 2015-2019," *Sinomika J. Publ. Ilm. Bid. Ekon. dan Akunt.*, vol. 1, no. 5, pp. 1075–1092, 2023.
- [5] Y. Maurina, R. R. Hidayat, and S. Sulasmiyati, "Pengaruh Tingkat Inflasi, Kurs Rupiah dan Tingkat Suku Bunga BI Rate Terhadap IHSG," *J. Adm. Bisnis SI Univ. Brawijaya*, vol. 27, no. 2, 2015.
- [6] S. Wulandari, S. A. Hutabarat, T. Sihombing, M. Simanjuntak, and R. Khairani, "Pengaruh Inflasi, BI Rate Dan Nilai Kurs Dollar As Terhadap Indeks Harga Saham Gabungan (IHSG) Yang Terdaftar Di Bursa Efek Indonesia (BEI)," *J. Econ. Bus. Account.*, vol. 4, no. 2, pp. 779–786, 2021.
- [7] F. Wang, M. Li, Y. Mei, and W. Li, "Time Series Data Mining: A Case Study with Big Data Analytics Approach," *IEEE Access*, vol. 8, pp. 14322–14328, 2020.
- [8] J. L. Chen, G. Li, D. C. Wu, and S. Shen, "Forecasting Seasonal Tourism Demand Using a Multiseries Structural Time Series Method," *J. Travel Res.*, vol. 58, no. 1, pp. 92–103, 2019.
- [9] J. H. Stock and M. W. Watson, "Vector Autoregressions," *J. Econ. Perspect.*, vol. 15, no. 4, pp. 101–115, 2001.
- [10] R. Julian and M. R. Pribadi, "Peramalan Harga Saham Pertambangan pada Bursa Efek Indonesia (BEI) menggunakan Long Short Term Memory (LSTM)," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 3, pp. 1570–1580, 2021.
- [11] A. C. Caliwag and W. Lim, "Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications," *IEEE Access*, vol. 7, pp. 59680–59689, 2019.
- [12] E. Dave, A. Leonardo, M. Jeanice, and N. Hanafiah, "Forecasting Indonesia Exports Using a Hybrid Model ARIMA-LSTM," *Procedia Comput. Sci.*, vol. 179, pp. 480–487, 2021.
- [13] G. P. Zhang, "Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model," *Neurocomputing*, vol. 50, pp. 159–175, 2003.
- [14] W. W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*, 2nd ed. Pearson Addison Wesley, 2006.
- [15] X. Luo, D. Zhang, and X. Zhu, "Deep Learning Based Forecasting of Photovoltaic Power Generation by Incorporating Domain Knowledge," *Energy*, vol. 225, p. 120240, 2021.
- [16] H. Mason and C. Wiggins, "A Taxonomy of Data Science," 2010. web.archive.org/web/20160220042455/dataists.com/2010/09/a-taxonomy-of-data-science/ (accessed Aug. 04, 2024).
- [17] N. Hotz, "OSEMN Data Science Life Cycle," *Data Science Process Alliance*, 2023. <https://www.datascience-pm.com/osemn> (accessed Aug. 04, 2024).
- [18] Y. Finance, "IDX Composite (^JKSE)," *Yahoo Finance*, 2024. <https://finance.yahoo.com/quote/%5EJKSE/> (accessed Aug. 10, 2024).
- [19] B. Indonesia, "Kalkulator Kurs," *Bank Indonesia*, 2024. <https://www.bi.go.id/id/statistik/informasi-kurs/transaksi-bi/kalkulator-kurs.aspx/> (accessed Aug. 10, 2024).