

# Comparative Study of Support Vector Regression and Long Short-Term Memory for Stock Price Prediction

Aviva Pradasyah <sup>1\*</sup>, Anna Baita <sup>2</sup>

\* Informatika, Universitas Amikom Yogyakarta

[aviva.pds@students.amikom.ac.id](mailto:aviva.pds@students.amikom.ac.id) <sup>1</sup>, [anna@amikom.ac.id](mailto:anna@amikom.ac.id) <sup>2</sup>

## Article Info

### Article history:

Received 2025-04-16

Revised 2025-06-18

Accepted 2025-07-03

### Keyword:

BBRI,  
time series,  
LSTM,  
Stock Price,  
SVR.

## ABSTRACT

This study aims to compare the performance of two machine learning algorithms, Long Short-Term Memory (LSTM) and Support Vector Regression (SVR), in predicting the stock prices of PT Bank Rakyat Indonesia (BBRI) using daily historical data from January 1, 2020, to January 10, 2025. The data were processed using a 60-day sliding window technique and normalized with MinMaxScaler. Model performance was evaluated using Mean Absolute Error (MAE), Mean Squared Error (MSE), and the coefficient of determination ( $R^2$ ) across five independent trials (5-fold trials). The evaluation results show that SVR outperforms in short-term prediction, with an average MAE of 0.0281, MSE of 0.0014, and  $R^2$  of 0.9072. Meanwhile, LSTM records an average MAE of 0.0312, MSE of 0.0015, and  $R^2$  of 0.8962, but achieves better performance in medium-term predictions, with a smaller average error of Rp228.02 compared to Rp242.52 from SVR. Both models demonstrate strong generalization capabilities on test data without signs of overfitting. Based on these findings, SVR is recommended for stable short-term forecasts, while LSTM is better suited for medium-term predictions involving complex trend patterns.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

## I. PENDAHULUAN

Saham atau yang sering disebut sebagai stock, adalah salah satu instrument investasi yang diminati banyak investor [1]. Instrument ini populer karena menawarkan potensi keuntungan yang cukup besar. Keuntungan tersebut bisa berupa *capital gain* atau deviden yang dibagikan kepada pemegang saham, baik secara berkala maupun tahunan [2]. Dalam instrumen investasi, dikenal konsep *risk* dan *reward*, khususnya pada investasi saham, terdapat prinsip "*high risk, high return*," yang menunjukkan bahwa potensi keuntungan yang tinggi biasanya datang dengan risiko yang besar [3]. Pasar saham merupakan salah satu indikator penting dalam perekonomian suatu negara.

Di Indonesia, Bank BRI adalah salah satu bank milik pemerintah atau Badan Usaha Milik Negara (BUMN) yang pertama kali tercatat di bursa efek pada tahun 2003. Pada saat itu, BRI memutuskan untuk menjual 30% sahamnya, menjadikannya perusahaan publik dengan nama PT. Bank Republik Indonesia Tbk, yang masih digunakan hingga saat

ini [4]. PT Bank Rakyat Indonesia (BBRI) menjadi perusahaan publik yang mendapat perhatian besar dari para investor. BBRI dikenal sebagai lembaga keuangan dengan kinerja stabil dan pertumbuhan yang terus meningkat, sehingga menjadi pilihan utama bagi investor yang mencari peluang investasi jangka panjang [5]. Sama halnya saham di pasar lain, harga saham BBRI sangat fluktuatif dan dipengaruhi oleh berbagai faktor eksternal dan internal seperti kondisi ekonomi mikro, kebijakan pemerintah, dan perubahan perilaku konsumen [6].

Prediksi harga saham merupakan tantangan yang kompleks karena melibatkan analisis data historis serta pengenalan pola yang sulit [7]. Dengan perkembangannya teknologi, terutama di bidang kecerdasan buatan dan *machine learning*, para peneliti dan praktisi mulai mengeksplorasi metode tersebut untuk meningkatkan dalam meramalkan pergerakan harga saham [8]. Dalam penelitian ini, ada 2 metode yang sering di gunakan dalam meramalkan pergerakan harga saham, yaitu *Support Vector Regression* (SVR) [9] dan *Long Short-Term Memory* (LSTM) [10]. Setiap metode memiliki pendekatan

dan karakteristik yang berbeda, sehingga di perlukan analisis komperatif untuk menentukan model mana yang paling efektif dalam memprediksi harga saham BBRI.

Algoritma *Support Vector Regression* (SVR) adalah pengembangan dari model regresi pada algoritma *Support Vector Machine* (SVM), yang diterapkan untuk menyelesaikan masalah atau kasus yang berhubungan dengan klasifikasi. Pada penelitian Atmaja [11], menerapkan model *Support Vector Regresi* (SVR) untuk memprediksi penutupan harian solana, hasilnya menunjukan bahwa kernel Linear dengan parameter  $cost\ C = 1000$  mencapai akurasi 97,44% dan MAPE 9,93, sedangkan kernel RBF dengan  $C = 1000$  dan  $gamma = 0.1\gamma$  menghasilkan akurasi 87,76% dan MAPE 8,14. Ini menunjukan bahwa kernel Linear lebih unggul dalam akurasi dan tingkat kesalahan dibandingkan kernel RBF.

Algoritma *Long Short Term Memory* (LSTM) adalah salah satu jenis arsitektur dari *Recurrent Neural Network* (RNN) yang sering digunakan untuk menangani masalah yang berkaitan dengan *deep learning* [12]. Dalam penelitian Widi dkk [4], menggunakan metode *Long Short-Term Memory* (LSTM) dalam prediksi saham BBRI. Hasil penelitian menunjukan bahwa metode *Long Short Term Memory* (LSTM) menghasilkan nilai *Root Mean Square Error* (RMSE) sebesar 1%, yang lebih baik dibandingkan dengan metode ARIMA yang memiliki RMSE 2.46%, dan akurasi yang dicapai oleh LSTM mencapai 99% dalam proyeksi saham BBRI. Selain itu penelitian ini hanya menggunakan data dari tahun 2005 hingga 2020, penelitian yang lebih lanjut dapat mencakup data yang lebih baru untuk meningkatkan relevansi dan akurasi proyeksi.

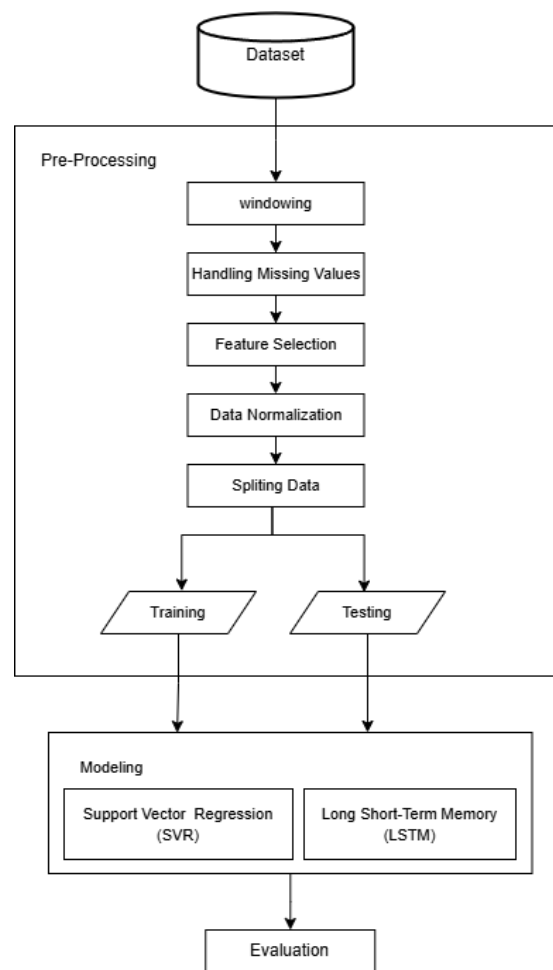
Penelitian ini bertujuan untuk membandingkan kinerja metode *Support Vector Regression* (SVR) dan *Long Short Term-Memory* (STM) dalam memprediksi harga saham BBRI menggunakan data historis. Perbandingan ini penting karena adanya keterbatasan metode tradisional dalam menangkap kompleksitas data saham, serta minimnya studi yang membandingkan langsung kedua metode ini. Penelitian ini akan mengidentifikasi model dengan akurasi prediksi tertinggi, mengevaluasi faktor-faktor yang mempengaruhi kinerja, dan memberikan rekomendasi praktisi bagi investor dan praktisi keuangan. Hasil penelitian ini diharapkan dapat meningkatkan akurasi prediksi harga saham, membantu investor dalam pengambilan keputusan, dan menjadi referensi bagi peneliti selanjutnya.

## II. METODE

### A. Dataset

Langka pertama dalam penelitian ini adalah mengumpulkan data saham Bank BRI dari situs *Yahoo Finance* (<https://finance.yahoo.com/>). Platform ini telah menyediakan data saham yang dapat diakses secara gratis. Data saham BBRI yang diambil memiliki *time frame* bulanan. Setelah data diperoleh, dilakukan proses *pre-processing* untuk menyesuaikan agar berada dalam format *time frame*

bulanan. Selain itu, data yang tersedia cukup lengkap, mencakup data sejak tahun 2003, yaitu saat pertama kali saham BBRI diperdagangkan secara publik di pasar saham, hingga saat ini [13].



Gambar 1. Diagram Alur Penelitian

### B. Pre-Processing

Data *pre-processing* merupakan langkah yang dilakukan guna mempersiapkan data agar dapat digunakan pada tahap selanjutnya [14]. Proses persiapan data ini sangat krusial sebelum digunakan dalam model *Support Vector Regression* (SVR) dan *Long Short-Term Memory* (LSTM). Tahapan utama dalam pra-pemrosesan meliputi beberapa langkah penting. Pertama, data yang akan digunakan akan dinormalisasi menggunakan metode *Min-Max* untuk memastikan rentang nilai yang konsisten. Setelah itu, data dibagi menjadi dua bagian: data latih (*training*) dan data uji (*testing*) untuk evaluasi model. Langkah terakhir dalam pra-pemrosesan ini adalah pembentukan *timestep*, yang bertujuan untuk mempersiapkan *data time-series* dengan menentukan target prediksi untuk setiap langkah waktu yang relevan [15].

### 1) Windowing

*Windowing* adalah teknik dalam analisis deret waktu (*time series*) yang digunakan untuk mengubah data historis menjadi potongan-potongan data berurutan (jendela) dengan ukuran tertentu. Teknik ini memungkinkan model untuk mempelajari pola temporal dari sejumlah data masa lalu guna memprediksi nilai masa depan. *Windowing* efektif dalam mengurangi fluktuasi jangka pendek dan mengungkap tren jangka panjang. Misalnya, untuk memprediksi harga pada hari ke-61, digunakan data harga dari hari ke-1 hingga ke-60. Rumus umumnya adalah

$$X_t = [X_t - n, X_t - n + 1, \dots, X_t - 1], y_t = X_t \quad (1)$$

Di mana  $X_t$  adalah input berupa *window* sepanjang  $n$  hari sebelum waktu  $t$ , dan  $y_t$  adalah nilai target pada waktu  $t$ .

### 2) Missing Values

*Missing values* adalah data yang hilang atau tidak tersedia dalam suatu dataset. Kehadiran nilai yang hilang dapat disebabkan oleh berbagai alasan, seperti kesalahan input data, penghapusan data yang tidak valid, atau keterbatasan dalam pengumpulan data. *Missing values* perlu ditangani karena dapat memengaruhi analisis, hasil model prediktif, dan interpretasi data [16].

### 3) Fitur Selection

*Fitur selection* (pemilihan fitur) adalah proses untuk memilih fitur-fitur yang paling relevan dari sekumpulan fitur yang tersedia dalam dataset, dengan tujuan meningkatkan kinerja model prediksi serta mengurangi kompleksitas perhitungan. Proses ini penting karena fitur yang tidak relevan dapat menurunkan akurasi model dan menyebabkan *overfitting*. Pemilihan fitur dapat dilakukan berdasarkan nilai korelasi atau pengaruh fitur terhadap target. Salah satu metode dasar adalah menggunakan korelasi Pearson, yang dirumuskan sebagai:

$$r = \frac{\sum(X_i - \bar{X})(y_i - \bar{y})}{\sqrt{\sum(X_i - \bar{X})^2} \sqrt{\sum(y_i - \bar{y})^2}} \quad (2)$$

di mana  $r$  menunjukkan kekuatan hubungan linier antara fitur  $x$  dan target  $y$ , semakin tinggi nilai absolut  $r$ , semakin relevan fitur tersebut.

### 4) Data Normalization

Normalisasi adalah proses mengubah data ke dalam skala yang seragam, biasanya antara 0 dan 1, untuk mempermudah analisis dan meningkatkan kinerja model *machine learning*, terutama yang bergantung pada jarak antar data. Jenis-jenis normalisasi data:

- Min-Max Normalization*: Mengubah data ke dalam rentang  $[0,1]$ , yang membuat data lebih mudah diproses oleh model *machine learning*.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3)$$

- $X$  : Nilai asli dari data.
- $X'$  : Nilai yang sudah di normalisasi.
- $X_{min}$  : Nilai terkecil dalam dataset.
- $X_{max}$  : Nilai terbesar dalam dataset.

### b. Z-score Normalization (Standardisasi)

*Z-score Normalization* mengubah data sehingga memiliki rata-rata (*mean*) 0 dan standar deviasi (*standard deviation*) 1. Ini berguna jika distribusi data tidak beraturan dan model memerlukan data yang terdistribusi secara normal.

$$Z = \frac{X - \mu}{\sigma} \quad (4)$$

- $X$  : Nilai asli dari data.
- $\mu$  : Rata-rata dari data (*mean*).
- $\sigma$  : Standar deviasi dari data (*standard deviation*).

### c. Robust Scaling

*Robust Scaling* adalah normalisasi yang menggunakan median dan *interquartile range* (IQR) untuk mengurangi pengaruh *outlier* (pencilan). Ini lebih stabil ketika ada data pencilan.

$$X_{scaled} = \frac{X - Median}{IQR} \quad (5)$$

- $X$  : Nilai asli dari data.
- Median : Nilai tengah data.
- IQR (*Interquartile Range*) : Selisih antara kuartil pertama (Q1) dan kuartil ketiga (Q3), yaitu  $IQR = Q3 - Q1$ .

### 4) Splitting Data

*Splitting data* adalah proses membagi dataset menjadi dua bagian utama untuk melatih dan menguji model *machine learning*:

#### a. Data Training (Training Set)

*Data training* adalah subset dari dataset yang digunakan untuk melatih model dalam pembelajaran mesin. Tujuan utama dari data *training* adalah untuk memungkinkan model mempelajari pola, hubungan, dan karakteristik yang ada dalam data tersebut, sehingga model dapat membuat prediksi yang akurat pada data baru yang belum pernah dilihat sebelumnya. Data *training* biasanya terdiri dari 70%-80% dari total dataset, bergantung pada kebutuhan dan ukuran dataset.

Fungsi utama:

- Membangun mode : Data *training* digunakan untuk melatih model sehingga model dapat belajar mengenali pola atau hubungan antara data.
- Menentukan parameter model : Melalui data *training*, model menentukan parameter-parameter penting seperti bobot atau koefisien yang di gunakan untuk prediksi di masa mendatang.

#### b. Data Testing (Testing Set)

Data *testing* adalah subset dari dataset yang digunakan untuk menguji kinerja model yang telah dilatih menggunakan data *training*. Tujuan utama data *testing* adalah untuk mengevaluasi seberapa baik model dapat menggeneralisasi pola yang telah dipelajari pada data yang belum pernah dilihat sebelumnya, serta untuk menilai akurasi dan efektivitas model dalam memprediksi data baru. Data *testing* biasanya terdiri dari 20% - 30% dari total dataset, tergantung pada ukuran dataset dan tujuan analisis.


Fungsi utama:

- Evaluasi kinerja model: Data *testing* digunakan untuk menguji prediksi yang dihasilkan model dan membandingkannya dengan data yang sebenarnya
- Mengukur generalisasi: Data *testing* membantu mengukur sejauh mana model dapat bekerja dengan baik pada data baru yang tidak ada dalam data *training*

### C. Permodelan

#### 1) Support Vector Regression (SVR)

*Support Vector Regression* (SVR) adalah metode regresi yang dikembangkan dari konsep *Support Vector Machine* (SVM) dan menghasilkan output berupa nilai kontinu atau bilangan *real*. SVR bekerja dengan prinsip minimisasi risiko struktural untuk meminimalkan kesalahan generalisasi dan menghindari *overfitting*. Tujuan utama algoritma ini adalah menemukan *hyperplane* terbaik, yaitu garis pemisah optimal yang dicapai dengan mengukur margin, yakni jarak antara *hyperplane* dan pola data terdekat. Pola yang paling dekat dengan margin ini disebut sebagai *Support Vector*. Dengan cara ini, SVR mampu menghasilkan prediksi yang lebih akurat meskipun menghadapi data yang kompleks atau tidak linier [17][18]. Gambar 2 menunjukan ilustrasi model SVR.



Gambar 2. Ilustrasi Model SVR

- *Hyperplane* (Garis Biru): Merupakan garis yang memisahkan data dalam ruang fitur untuk prediksi. Pada SVR, *hyperplane* digunakan untuk memodelkan hubungan antara variabel input dan output.
- *Boundary Lines* (Garis Orange): Menunjukkan batas kesalahan yang dapat diterima, yaitu batas epsilon ( $\epsilon$ ). Data yang berada di luar batas ini dianggap sebagai kesalahan yang lebih besar.
- *Slack Variables* ( $\xi$  dan  $\xi^*$ ): Menggambarkan deviasi atau kesalahan yang diperbolehkan dari prediksi, yang diperbolehkan berada di luar margin epsilon.

Rumus-rumus dalam SVR:

#### a. Model Prediksi ( $F(X)$ )

$$f(x) = w \cdot x + b \quad (6)$$

Di mana:

- $F(x)$  : prediksi untuk input  $x$ .
- $W$  : vektor bobot yang mengontrol orientasi *hyperplane*.
- $b$  : bias atau intersep.

#### b. Fungsi Tujuan (Loss Function)

Fungsi tujuan dalam metode SVR adalah untuk meminimalkan kesalahan prediksi sambil menjaga margin kesalahan yang bisa diterima.

$$\text{Min } \frac{1}{2} ||w||^2 \quad (7)$$

Dengan *constraint* (batasan) bahwa:

$$|y_i - (w \cdot x_i + b)| \leq \epsilon \quad (8)$$

Di mana:

- $y_i$  adalah nilai aktual dari data  $i$ .
- $x_i$  adalah input dari data  $i$ .
- $\epsilon$  adalah margin kesalahan yang dapat diterima.

c. Fungsi Kewajiban (*Slack Variables*)

Jika ada data yang berada di luar margin epsilon maka deviasi tersebut dihitung menggunakan *slack variables*

$$\varepsilon_i = \max(0, |y_i - (w \cdot x_i + b)| - \epsilon) \quad (9)$$

d. Fungsi Optimasi (*Objective Function*)

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \varepsilon_i \quad (10)$$

Di mana:

- C adalah parameter yang mengontrol *trade off* antara margin yang lebih besar dan kesalahan data (penalti terhadap *slack variables*)
- $\varepsilon_i$  adalah *slack variables* untuk data i.

2) Long Short-Term Memory (LSTM)

LSTM adalah jenis jaringan saraf tiruan (*neural network*) yang digunakan dalam *deep learning*, khususnya untuk menangani data berurutan atau urutan waktu, seperti data *time series*, teks, atau data sekuensial lainnya. LSTM adalah jenis dari *Recurrent Neural Network (RNN)* yang dapat mengatasi masalah *vanishing gradient*, yang biasanya terjadi pada RNN tradisional saat mengolah urutan panjang [19]. LSTM sangat efektif untuk aplikasi yang memerlukan prediksi berdasarkan urutan data sebelumnya, seperti prediksi stok harga, cuaca, atau bahkan penerjemahan bahasa [20].

LSTM memiliki sel memori yang memungkinkan jaringan untuk mengingat informasi dalam waktu yang lama dan memutuskan informasi mana yang harus dipertahankan dan mana yang harus dilupakan. LSTM terdiri dari tiga gerbang utama yang mengatur aliran informasi:

a. Forget Gate (Gerbang Lupa)

Gerbang ini menentukan informasi mana yang harus dibuang dari sel memori. Menggunakan fungsi aktivasi sigmoid, gerbang ini memberikan nilai antara 0 dan 1 untuk setiap angka dalam sel memori sebelumnya. Nilai 0 berarti "lupa", dan nilai 1 berarti "ingat".

$$f_t = \sigma(W_f \cdot [h_t - 1, x_t] + b_f) \quad (11)$$

Di mana:

- $f_t$  : nilai untuk *forget gate*.
- $W_f$  : bobot untuk *forget gate*.
- $h_t - 1$  : output dari langkah sebelumnya.
- $x_t$  : input pada waktu t.
- $b_f$  : bias.

b. Input Gate (Gerbang Input)

Gerbang ini memutuskan informasi baru apa yang akan ditambahkan ke dalam sel memori. Pertama, digunakan fungsi sigmoid untuk menentukan seberapa banyak informasi yang akan diperbarui, kemudian fungsi tanh untuk membuat vector kandidat nilai yang akan ditambahkan ke sel memori.

$$i_t = \sigma(W_i \cdot [h_t - 1, x_t] + b_i) \quad (12)$$

$$C_t = \tanh(W_c \cdot [h_t - 1, x_t] + b_c) \quad (13)$$

Di mana:

- $i_t$  : nilai untuk input gate.
- $C_t$  : vector kandidat untuk nilai baru yang akan dimasukkan ke dalam sel memori.

c. Output Gate (Gerbang Output)

Gerbang ini menentukan apa yang akan dikeluarkan dari sel memori dan menjadi output dari LSTM. Ini menggabungkan informasi dari sel memori yang diperbarui dengan fungsi sigmoid untuk menghasilkan output yang sesuai.

$$o_t = \sigma(W_o \cdot [h_t - 1, x_t] + b_o) \quad (14)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (15)$$

Di mana:

- $o_t$  adalah nilai untuk output gate.
- $C_t$  adalah nilai sel memori pada waktu t.
- $h_t$  adalah output dari LSTM pada waktu t.

D. Evaluation

*Evaluation* adalah proses menilai kinerja model *machine learning* berdasarkan metrik tertentu untuk memahami seberapa baik model membuat prediksi pada data baru dan seberapa efektif dalam menangkap pola data. Tujuannya adalah untuk menilai keakuratan dan keandalan model, mendeteksi *overfitting* atau *underfitting*, serta membandingkan beberapa model untuk memilih yang terbaik. Dalam klasifikasi, metrik yang sering digunakan meliputi akurasi, *precision*, *recall*, dan *F1-score*, sementara untuk regresi biasanya menggunakan *MAE (Mean Absolute Error)*, *MSE (Mean Squared Error)*, dan *R<sup>2</sup> (R-Squared)*. Evaluasi ini penting untuk memastikan bahwa model bekerja secara optimal sebelum digunakan dalam prediksi dunia nyata [21].

### III. HASIL DAN PEMBAHASAN

A. Dataset

Data saham yang digunakan dalam penelitian ini merupakan data saham PT Bank Rakyat Indonesia (Persero) Tbk (BBRI) yang diperoleh dari platform *Yahoo Finance*, sebuah sumber terpercaya yang menyediakan informasi keuangan dan pasar saham. Data tersebut disusun dalam bentuk tabel berdasarkan harga historis saham yang tersedia, dengan total sebanyak 1.218 data yang mencakup periode dari tahun 1 januari 2020 hingga 10 januari 2025.

TABEL I  
HARGA SAHAM BBRI

| Date        | Close  | High   | Low    | Open   | Volume    |
|-------------|--------|--------|--------|--------|-----------|
| 2020-01-02  | 3132   | 3132   | 3097   | 3125   | 45886302  |
| 2020-01-03  | 3139   | 3153   | 3118   | 3139   | 91189705  |
| 2020-01-06  | 3104   | 3118   | 3068   | 3097   | 48648450  |
| 2020-01-07  | 3125   | 3132   | 3111   | 3132   | 114344885 |
| 2020-01-08  | 3111   | 3125   | 3082   | 3111   | 188929583 |
| ...         | ...    | ...    | ...    | ...    | ...       |
| 2025-01-06  | 4100.0 | 4180.0 | 4100.0 | 4180.0 | 153048700 |
| 2025-01-07  | 4030.0 | 4090.0 | 4030.0 | 4080.0 | 171997400 |
| 2025-01-08  | 4080.0 | 4100.0 | 4030.0 | 4030.0 | 133655700 |
| 2025-01-09  | 4030.0 | 4100.0 | 4030.0 | 4070.0 | 99300400  |
| 2025-01-010 | 4010.0 | 4060.0 | 4010.0 | 4030.0 | 132774300 |

Tabel I di atas menampilkan data historis saham beserta atribut yang digunakan dan jenis datanya. *Atribut Date, Open, High, Low, dan Volume* berfungsi sebagai variabel independen, sedangkan atribut *Close* berperan sebagai label atau variabel dependen.

## B. Pre-Processing Data

### 1) Windowing

TABEL II  
KONFIGURASI SLIDING WINDOW

| Komponen       | Penjelasan   |
|----------------|--|
| X (Independen) | Sekuens 60 hari terakhir dari harga pembukaan saham ( <i>Open_Scaled</i> ) |
| Y (Dependen)   | Harga pembukaan saham pada hari ke-61 setelah data 60 hari tersebut        |
| Fungsi         | X digunakan sebagai input untuk memprediksi Y                              |
| Window size    | 60 Hari  |

Dalam penelitian ini, data harga saham harian BBRI.JK yang diperoleh dari *Yahoo Finance* digunakan secara langsung tanpa diubah ke dalam bentuk mingguan atau bulanan. Untuk membentuk input bagi model prediksi, digunakan pendekatan *sliding window* dengan panjang jendela (*window size*) sebanyak 60 hari. Artinya, setiap 60 data harga pembukaan (*Open*) digunakan sebagai dasar untuk memprediksi harga pada hari ke-61. Proses ini diulang secara bergeser (*sliding*) sepanjang data, baik saat pelatihan maupun pengujian model, dan diterapkan pada kedua metode: LSTM dan SVR. Dengan tetap menggunakan data harian, model dapat menangkap pola jangka pendek dan fluktuasi pasar

secara lebih detail karena tidak ada informasi yang hilang akibat penggabungan data (agregasi).

### 2) Missing Value

Hasil analisis menunjukkan bahwa data saham BBRI.JK yang digunakan tidak mengandung *missing values*. Berdasarkan output yang ditampilkan, seluruh kolom seperti (*Close, High, Low, Open, dan Volume*) terisi secara lengkap tanpa adanya nilai yang kosong. Dengan demikian, data yang digunakan dalam analisis ini dapat dipastikan bersih dan siap untuk diproses lebih lanjut.

Dengan tidak adanya *Missing values*, proses analisis dapat dilanjutkan tanpa perlu melakukan imputasi atau penghapusan data yang hilang. Keberhasilan ini menunjukkan bahwa data yang diperoleh dari sumber *Yahoo Finance* dalam hal ini sudah cukup terstruktur dan bersih. Oleh karena itu, langkah berikutnya dalam analisis model prediksi, dapat dilakukan tanpa gangguan yang disebabkan oleh data yang hilang.

### 3) Fitur selection

Dalam penelitian ini, fitur yang dipilih untuk digunakan sebagai input model prediksi adalah kolom "*Open*", yang merepresentasikan harga pembukaan saham harian. Pemilihan fitur ini bukan tanpa alasan, melainkan berdasarkan pada karakteristik unik dari harga pembukaan. Harga pembukaan mencerminkan reaksi awal pasar terhadap informasi terbaru yang tersedia sebelum sesi perdagangan dimulai, seperti berita ekonomi, laporan keuangan, atau sentimen global. Oleh karena itu, harga pembukaan sering dianggap sebagai indikator penting terhadap arah pergerakan harga intraday (harian). Dengan memfokuskan pada satu fitur utama ini, kompleksitas data dapat dikurangi tanpa menghilangkan sinyal penting yang relevan bagi proses prediksi.

### 4) Data Normalization

Langkah berikutnya adalah melakukan proses normalisasi data menggunakan metode *MinMaxScaler* dari pustaka *sklearn.preprocessing*. Metode ini mengubah nilai-nilai pada kolom "*Open*" ke dalam rentang skala antara 0 hingga 1, sesuai dengan rumus normalisasi *Min-Max*. Tujuan utama dari normalisasi ini adalah untuk memastikan bahwa seluruh input memiliki skala yang seragam sehingga model, baik LSTM maupun SVR, dapat belajar dengan lebih optimal. Tanpa normalisasi, model mungkin akan bias terhadap nilai-nilai besar dan mengalami kesulitan dalam proses konvergensi saat pelatihan. Dengan data yang telah dinormalisasi, model mampu mengenali pola historis dengan lebih konsisten, stabil, dan akurat. Tabel III berikut adalah tabel data sebelum dan sesudah di normalisasikan.

TABEL III  
HARGA OPEN BBRI SEBELUM VS SESUDAH NORMALISASI

| Tanggal    | Sebelum     | Sesudah  |
|------------|-------------|----------|
| 2020-01-02 | 2954.12952  | 0.330167 |
| 2020-01-03 | 2967.557373 | 0.333369 |
| 2020-01-06 | 2927.273568 | 0.323762 |
| .....      | .....       | .....    |
| 2025-01-08 | 3808.986247 | 0.534018 |
| 2025-01-09 | 3846.792644 | 0.543033 |
| 2025-01-10 | 3808.986165 | 0.534018 |

### 5) Splitting Data

#### a. Training

Pada tahap pelatihan, data historis saham terlebih dahulu dinormalisasi menggunakan metode *Min-Max Scaling*. Dataset yang digunakan terdiri dari 1.218 data historis harga pembukaan saham dari tahun 2020 hingga 2025. Setelah proses normalisasi, data dibagi menjadi dua bagian, yaitu 80% (974) untuk pelatihan dan 20% (244 data) untuk pengujian. Pembagian ini dilakukan dengan metode *single split*.

LSTM dan SVR dapat dibandingkan secara adil, dilakukan proses rekayasa fitur dengan menggunakan teknik *sliding window*. Dalam pendekatan ini, setiap input terdiri dari 60 hari data harga pembukaan sebelumnya, dan target output-nya adalah harga pada hari ke-61. Dataset awal yang telah dinormalisasi dibagi menjadi dua bagian: 80% data digunakan untuk pelatihan, dan 20% sisanya untuk pengujian. Proses pembentukan pasangan input-output dilakukan secara iteratif, lalu data dibentuk dalam format yang disesuaikan dengan masing-masing model.

Tabel IV berikut menunjukkan dimensi input untuk model LSTM dan SVR setelah diterapkan teknik *sliding window*.

TABEL IV  
DIMENSI INPUT UNTUK MODEL LSTM DAN SVR

| Model | Dimensi Input                  | Penjelasan  |
|-------|--------------------------------|---|
| LSMT  | (samples, timesteps, features) | - samples : jumlah sampel pelatihan<br>- timesteps : 60 (hari sebelumnya)<br>- features : 1 (harga pembukaan) |
| SVR   | (samples, features)            | - samples : jumlah sampel pelatihan<br>- features : 60 (masing masing mewakili 1 hari sebelumnya)             |

Dengan format ini, baik LSTM maupun SVR menerima data konteks histori 60 hari yang setara, meskipun dalam bentuk struktur input yang berbeda.

#### b. Testing

Setelah proses pelatihan selesai, sisa data sebanyak 20% dari keseluruhan dataset digunakan sebagai data pengujian untuk mengevaluasi performa model. Sama seperti pada tahap *pelatihan*, pasangan input-output untuk pengujian dibentuk menggunakan teknik *sliding window* dengan panjang jendela 60 hari. Setiap input berisi data harga pembukaan selama 60

hari terakhir, sedangkan target output-nya adalah harga pembukaan pada hari ke-61. Format input pada tahap pengujian disesuaikan dengan struktur masing-masing model: data diubah ke dalam format tiga dimensi (*samples, timesteps, features*) untuk LSTM dan dua dimensi (*samples, features*) untuk SVR.

Untuk memperoleh hasil evaluasi yang lebih akurat dan dapat diandalkan, proses pelatihan dan pengujian ini dilakukan sebanyak lima kali (*5-fold trials*). Setiap percobaan menghasilkan nilai evaluasi seperti MAE, MSE, dan R<sup>2</sup>, yang kemudian dirata-rata dan dihitung standar deviasinya. Pendekatan ini memberikan gambaran lebih objektif terhadap stabilitas performa masing-masing model dalam memprediksi data yang belum pernah dilihat sebelumnya.

### C. Permodelan

Penelitian ini menggunakan dua algoritma, yaitu *Long Short-Term Memory (LSTM)* dan *Support Vector Regression (SVR)*, untuk membandingkan performa model dalam memprediksi harga saham BBRI dan menilai keunggulan masing-masing algoritma.

#### 1. Long Short-Term Memory (LSTM)

Model LSTM dalam penelitian ini dirancang menggunakan dua lapisan LSTM yang disusun secara berurutan. Jumlah unit pada setiap lapisan serta parameter lainnya ditentukan melalui proses *Random search*, yang mencakup variasi jumlah unit (32 dan 50), tingkat *dropout* (0.2 dan 0.3), *learning rate* (0.001 dan 0.005), *batch size* (16 dan 32), dan jumlah *epoch* (30). Lapisan pertama dikonfigurasi dengan *return\_sequences=True* agar output-nya dapat dilanjutkan ke lapisan LSTM berikutnya, sedangkan lapisan kedua menggunakan *return\_sequences=False* untuk menghasilkan representasi akhir sebelum masuk ke lapisan output.

Setelah masing-masing lapisan LSTM, diterapkan *Dropout* untuk mengurangi risiko *overfitting*. Output akhir diproses oleh lapisan *Dense* dengan satu *neuron* yang berfungsi menghasilkan prediksi harga saham pada langkah waktu berikutnya. *Optimizer* yang digunakan adalah Adam, dengan nilai *learning rate* yang bervariasi sesuai kombinasi dalam *grid search*. Input model berupa urutan data sepanjang 10 *time steps*, yang mencerminkan pola historis jangka pendek dari harga saham. Konfigurasi terbaik dipilih berdasarkan nilai *loss* validasi terendah yang diperoleh selama proses pelatihan.

Untuk memperoleh parameter terbaik dari model LSTM, dilakukan serangkaian percobaan menggunakan kombinasi parameter secara acak (*random grid search*). Tabel V berikut menyajikan beberapa kombinasi parameter yang diuji dalam percobaan pertama.

TABEL V



KOMBINASI PARAMETER UJI COBA LSTM (PERCOBAAN 1–5) MELALUI RANDOM GRID SEARCH

| Percobaan 1 | Unit | Learning_rate | Epoch | Dropout | Batch_Size |
|-------------|------|---------------|-------|---------|------------|
| Trial 1     | 50   | 0.005         | 30    | 0.3     | 16         |
| Trial 2     | 50   | 0.001         | 30    | 0.2     | 32         |
| Trial 3     | 50   | 0.001         | 30    | 0.3     | 16         |
| Trial 4     | 32   | 0.001         | 30    | 0.3     | 32         |
| Trial 5     | 50   | 0.001         | 30    | 0.2     | 32         |
| Percobaan 2 | Unit | Learning_rate | Epoch | Dropout | Batch_Size |
| Trial 1     | 32   | 0.001         | 30    | 0.3     | 32         |
| Trial 2     | 50   | 0.001         | 30    | 0.3     | 16         |
| Trial 3     | 50   | 0.001         | 30    | 0.2     | 32         |
| Trial 4     | 32   | 0.001         | 30    | 0.3     | 32         |
| Trial 5     | 50   | 0.005         | 30    | 0.2     | 16         |
| Percobaan 3 | Unit | Learning_rate | Epoch | Dropout | Batch_Size |
| Trial 1     | 32   | 0.001         | 30    | 0.3     | 16         |
| Trial 2     | 50   | 0.005         | 30    | 0.3     | 16         |
| Trial 3     | 32   | 0.005         | 30    | 0.2     | 16         |
| Trial 4     | 50   | 0.001         | 30    | 0.3     | 16         |
| Trial 5     | 50   | 0.001         | 30    | 0.2     | 32         |
| Percobaan 4 | Unit | Learning_rate | Epoch | Dropout | Batch_Size |
| Trial 1     | 32   | 0.001         | 30    | 0.3     | 16         |
| Trial 2     | 32   | 0.001         | 30    | 0.3     | 32         |
| Trial 3     | 32   | 0.005         | 30    | 0.2     | 16         |
| Trial 4     | 50   | 0.005         | 30    | 0.2     | 16         |
| Trial 5     | 50   | 0.001         | 30    | 0.2     | 32         |
| Percobaan 5 | Unit | Learning_rate | Epoch | Dropout | Batch_Size |
| Trial 1     | 32   | 0.001         | 30    | 0.3     | 16         |
| Trial 2     | 32   | 0.001         | 30    | 0.3     | 16         |
| Trial 3     | 50   | 0.001         | 30    | 0.3     | 16         |
| Trial 4     | 32   | 0.001         | 30    | 0.3     | 16         |
| Trial 5     | 32   | 0.001         | 30    | 0.3     | 16         |

Berdasarkan hasil random *grid search*, Tabel VI berikut menyajikan kombinasi parameter terbaik yang digunakan dalam pelatihan model LSTM

TABEL VI  
HYPERPARAMETER TERBAIK LSTM

| Hyperparameter | Nilai Optimal |
|----------------|---------------|
| Units          | 50            |
| Dropout        | 0.3           |
| Learning Rate  | 0.005         |
| Batch Size     | 16            |
| Epochs         | 30            |

## 2. Support Vector Regression SVR

Model penelitian ini menggunakan algoritma *Support Vector Regression* (SVR) dengan *kernel Radial Basis Function* (RBF) untuk mengatasi hubungan non linier dalam data *time series*. Pemilihan parameter terbaik dilakukan melalui metode *Random Search* yang dikombinasikan dengan validasi silang berbasis waktu (*TimeSeriesSplit*) sebanyak 5 fold. *Hyperparameter* yang dieksplorasi mencakup C [1,10,100] gamma ['scale', 0.01, 0.1] dan epsilon [0.01,0.1] yang masing-masing berfungsi untuk mengatur kompleksitas

model, pengaruh setiap titik data terhadap *hyperplane*, serta toleransi terhadap kesalahan prediksi.

Input data untuk model ini berupa 10 langkah harga saham sebelumnya yang diratakan menjadi *array* berdimensi satu sebelum digunakan dalam pelatihan. Model dievaluasi berdasarkan nilai *Mean Squared Error* (MSE), serta digunakan untuk melakukan prediksi satu langkah ke depan maupun 15 hari ke depan menggunakan pendekatan *recursive multi-step prediction*. Pendekatan yang sama juga diterapkan pada model LSTM, memungkinkan perbandingan performa antar model dalam memproyeksikan tren harga saham jangka pendek dan menengah secara lebih akurat dan stabil.

Tabel VII di bawah ini menyajikan kombinasi *hyperparameter* SVR yang diuji pada masing-masing dari lima percobaan menggunakan pendekatan *random grid search*, serta menunjukkan keragaman konfigurasi yang digunakan dalam proses tuning model.

TABEL VII  
KOMBINASI PARAMETER UJI COBA SVR (PERCOBAAN 1–5) MELALUI RANDOM GRID SEARCH

| Percobaan 1 | C   | Epsilon | Gamma |
|-------------|-----|---------|-------|
| Trial 1     | 10  | 0.01    | scale |
| Trial 2     | 1   | 0.01    | 0.01  |
| Trial 3     | 1   | 0.1     | scale |
| Trial 4     | 1   | 0.01    | scale |
| Trial 5     | 1   | 0.01    | 0.01  |
| Percobaan 2 | C   | Epsilon | Gamma |
| Trial 1     | 1   | 0.1     | 0.01  |
| Trial 2     | 10  | 0.1     | 0.01  |
| Trial 3     | 10  | 0.1     | 0.01  |
| Trial 4     | 1   | 0.1     | 0.01  |
| Trial 5     | 10  | 0.1     | scale |
| Percobaan 3 | C   | Epsilon | Gamma |
| Trial 1     | 10  | 0.1     | scale |
| Trial 2     | 10  | 0.1     | scale |
| Trial 3     | 1   | 0.01    | scale |
| Trial 4     | 10  | 0.01    | scale |
| Trial 5     | 10  | 0.1     | scale |
| Percobaan 4 | C   | Epsilon | Gamma |
| Trial 1     | 1   | 0.01    | scale |
| Trial 2     | 100 | 0.1     | 0.01  |
| Trial 3     | 100 | 0.01    | 0.1   |
| Trial 4     | 100 | 0.01    | 0.1   |
| Trial 5     | 1   | 0.01    | 0.1   |
| Percobaan 5 | C   | Epsilon | Gamma |
| Trial 1     | 1   | 0.01    | 0.01  |
| Trial 2     | 1   | 0.01    | 0.01  |
| Trial 3     | 10  | 0.1     | scale |
| Trial 4     | 1   | 0.01    | scale |
| Trial 5     | 1   | 0.1     | 0.01  |

Berdasarkan hasil random *grid search*, Tabel VIII berikut menyajikan kombinasi parameter terbaik yang digunakan dalam pelatihan model SVR



TABEL VIII  
HYPERPARAMETER TERBAIK SVR

| Hyperparameter | Nilai Optimal |
|----------------|---------------|
| C              | 100           |
| Epsilon        | 0.01          |
| Gamma          | 0.01          |

#### D. Evaluasi

Setelah model LSTM dan SVR selesai dilatih dengan konfigurasi parameter terbaik masing-masing, tahap selanjutnya adalah melakukan evaluasi performa kedua model. Untuk memperoleh hasil evaluasi yang objektif, tidak bias, dan dapat diandalkan, proses pelatihan dan pengujian tidak hanya dilakukan sekali, melainkan diulang sebanyak lima kali percobaan independen (*5-fold trials*). Setiap percobaan menggunakan struktur data, teknik *sliding window*, serta parameter pelatihan yang sama, namun memungkinkan variasi internal seperti inisialisasi bobot (pada LSTM) agar kestabilan model dapat diukur secara statistik.

Hasil dari tiap percobaan kemudian dievaluasi menggunakan metrik *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan koefisien determinasi ( $R^2$ ). Nilai-nilai tersebut kemudian dihitung rata-ratanya dan deviasi standarnya untuk mendapatkan gambaran umum seberapa baik dan stabil masing-masing model dalam melakukan prediksi harga saham BBRI.

Tabel 7 dan 8 berikut menyajikan hasil prediksi pada hari ke-1 dan ke-15, disertai dengan selisih terhadap harga aktual sebagai ilustrasi awal akurasi model dalam konteks prediksi jangka pendek dan menengah.

TABEL IX  
PREDIKSI HARI KE-1 DAN SELISIH TERHADAP HARGA AKTUAL

| Tanggal                                 | LSTM             | SVR              |
|---|------------------|------------------|
| Prediksi Hari Ke-1<br>(11 Januari 2025) | 3905.44          | 3831.61          |
| Harga Real<br>(11 Januari 2025)         | 4,030.00         | 4.030.00         |
| <b>Rata-Rata</b>                        | <b>Rp 127,56</b> | <b>Rp 196,97</b> |

TABEL X  
PREDIKSI HARI KE-15 DAN SELISIH TERHADAP HARGA AKTUAL

| Tanggal                                  | LSTM             | SVR              |
|--|------------------|------------------|
| Prediksi Hari Ke-15<br>(25 Januari 2025) | 4034.66          | 4026.81          |
| Harga Real<br>(25 Januari 2025)          | 4,350            | 4,350            |
| <b>Rata-Rata</b>                         | <b>Rp 228,02</b> | <b>Rp 242,52</b> |

Model LSTM menghasilkan prediksi yang lebih stabil dan mengikuti tren dibandingkan SVR, yang cenderung lebih fluktuatif dan konservatif, terutama dalam prediksi jangka menengah.

Setelah hasil prediksi dibandingkan dalam Tabel IX dan X, Tabel XI menyajikan evaluasi kuantitatif yang


menggambarkan seberapa dekat hasil prediksi model LSTM dan SVR terhadap data aktual pada data uji, menggunakan metrik MAE, MSE, dan  $R^2$ .

TABEL XI  
METRIK EVALUASI

| MODEL                                      | MAE                                   | MSE                                   | R2                                    |
|--|---------------------------------------|---------------------------------------|---------------------------------------|
| LSTM percobaan 1                           | 0.0332                                | 0.0017                                | 0.8856                                |
| LSTM percobaan 2                           | 0.0352                                | 0.0001                                | 0.9585                                |
| LSTM percobaan 3                           | 0.0268                                | 0.0026                                | 0.8268                                |
| LSTM percobaan 4                           | 0.0294                                | 0.0014                                | 0.9103                                |
| LSTM percobaan 5                           | 0.0315                                | 0.0015                                | 0.8997                                |
| <b>LSTM rata-rata <math>\pm</math> std</b> | <b>0.0312 <math>\pm</math> 0.0025</b> | <b>0.0015 <math>\pm</math> 0.0008</b> | <b>0.8962 <math>\pm</math> 0.0450</b> |
| SVR percobaan 1                            | 0.0194                                | 0.0006                                | 0.9589                                |
| SVR percobaan 2                            | 0.0419                                | 0.0026                                | 0.8268                                |
| SVR percobaan 3                            | 0.0419                                | 0.0026                                | 0.8268                                |
| SVR percobaan 4                            | 0.0181                                | 0.0005                                | 0.9647                                |
| SVR percobaan 5                            | 0.0194                                | 0.0006                                | 0.9589                                |
| <b>LSTM rata-rata <math>\pm</math> std</b> | <b>0.0281 <math>\pm</math> 0.0105</b> | <b>0.0014 <math>\pm</math> 0.0009</b> | <b>0.9072 <math>\pm</math> 0.0702</b> |

Tabel XI menyajikan hasil evaluasi performa dari model LSTM dan SVR berdasarkan lima kali percobaan (*5-fold trials*), menggunakan tiga metrik regresi utama, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan koefisien determinasi ( $R^2$ ). Evaluasi dilakukan terhadap data uji untuk menilai tingkat akurasi dan kestabilan masing-masing model dalam melakukan prediksi harga saham BBRI.

diterapkan untuk prediksi jangka menengah yang membutuhkan pemahaman terhadap pola data yang lebih kompleks dan dinamis. Perbandingan ini memberikan pemahaman yang lebih komprehensif mengenai kelebihan dan kekurangan masing-masing pendekatan, serta memberikan dasar yang kuat untuk pemilihan model sesuai kebutuhan praktis di dunia nyata.



Gambar 3. Grafik Hasil Prediksi dengan Data Aktual (*Open Price*)

Berdasarkan hasil tersebut, model SVR menunjukkan performa yang sangat stabil dan akurat untuk prediksi jangka pendek. Hal ini tercermin dari rata-rata MAE sebesar 0.0281 dan MSE sebesar 0.0014, yang lebih rendah dibandingkan model LSTM. Selain itu, nilai  $R^2$  rata-rata sebesar 0.9072 mengindikasikan kemampuan SVR dalam menjelaskan variasi data aktual secara konsisten. Nilai standar deviasi yang relatif kecil pada ketiga metrik juga menegaskan kestabilan performa SVR antar percobaan.

Sementara itu, model LSTM menunjukkan performa yang cukup kompetitif dengan rata-rata  $R^2$  sebesar 0.8962. Meskipun hasil evaluasinya lebih fluktuatif dibandingkan SVR, hal tersebut dapat dimaklumi karena LSTM merupakan model jaringan saraf yang bersifat stokastik dan sangat dipengaruhi oleh inisialisasi bobot serta dinamika pelatihan. Namun, pada prediksi jangka menengah seperti hari ke-15, LSTM menunjukkan kecenderungan menghasilkan prediksi yang lebih dekat terhadap harga aktual, mengindikasikan kemampuannya dalam menangkap pola tren historis yang lebih kompleks.

Kedua model menunjukkan kemampuan generalisasi yang baik terhadap data uji. Tidak ditemukan indikasi *overfitting* yang signifikan, terlihat dari konsistensi hasil antar percobaan dan tidak adanya perbedaan ekstrem dalam nilai metrik evaluasi. Hal ini menunjukkan bahwa baik LSTM maupun SVR mampu melakukan prediksi terhadap data yang belum pernah dilihat sebelumnya dengan cukup akurat.

Secara keseluruhan, SVR lebih direkomendasikan untuk kebutuhan prediksi jangka pendek yang mengutamakan kestabilan dan presisi tinggi. Di sisi lain, LSTM cocok

Pada visualisasi prediksi harga saham BBRI yang ditampilkan dalam grafik di atas, terlihat bahwa model LSTM dan SVR masing-masing menghasilkan proyeksi pergerakan harga untuk periode akhir tahun 2024 hingga awal tahun 2025. Dalam kurva prediksi ini, model LSTM menunjukkan tren kenaikan harga saham yang cenderung stabil dan berkelanjutan, mencerminkan kemampuannya dalam mengenali pola historis yang konsisten dari data pelatihan sebelumnya. Sebaliknya, prediksi dari model SVR tampak lebih fluktuatif dan cenderung konservatif, dengan nilai prediksi yang umumnya lebih rendah daripada prediksi LSTM pada periode yang sama. Hal ini menunjukkan bahwa SVR kurang sensitif terhadap dinamika tren jangka pendek, sementara LSTM mampu menangkap pola-pola naik turunnya harga dengan lebih baik. Secara keseluruhan, visualisasi ini memperkuat hasil evaluasi numerik sebelumnya, di mana model LSTM terbukti lebih unggul dalam menghasilkan prediksi harga saham BBRI yang akurat dan realistis untuk horizon waktu jangka pendek ke awal 2025, menjadikannya lebih adaptif terhadap perubahan tren pasar yang berkembang.

#### IV. KESIMPULAN

Penelitian Penelitian ini berhasil membandingkan performa dua algoritma prediktif, yaitu *Long Short-Term Memory* (LSTM) dan *Support Vector Regression* (SVR), dalam memprediksi harga saham PT Bank Rakyat Indonesia (BBRI) berdasarkan data harian selama periode 1 Januari 2020 hingga 10 Januari 2025. Dengan menerapkan teknik *sliding window* selama 60 hari dan melakukan lima kali

percobaan (*5-fold trials*), penelitian ini mengevaluasi kinerja kedua model menggunakan metrik MAE, MSE, dan  $R^2$ .

Dari hasil evaluasi, model SVR menunjukkan performa unggul dalam prediksi jangka pendek. Hal ini tercermin dari nilai rata-rata MAE sebesar 0.0281 dan MSE sebesar 0.0014 dengan standar deviasi yang kecil, serta nilai  $R^2$  sebesar 0.9072 yang menunjukkan tingkat akurasi tinggi dan stabil antar percobaan. Sebaliknya, model LSTM memiliki nilai MAE rata-rata sebesar 0.0312 dan MSE sebesar 0.0015 dengan  $R^2$  sebesar 0.8962, yang meskipun sedikit lebih fluktuatif, tetap dalam rentang yang kompetitif.

Dalam konteks prediksi harga 15 hari ke depan, model LSTM menunjukkan performa lebih unggul dengan selisih rata-rata terhadap harga aktual sebesar Rp228,02, dibandingkan SVR yang memiliki selisih Rp242,52. Hal ini menandakan bahwa LSTM memiliki kelebihan dalam menangkap tren jangka menengah berkat kemampuannya mengenali pola historis yang lebih kompleks.

Kedua model menunjukkan kemampuan generalisasi yang baik terhadap data uji, tanpa indikasi *overfitting*. Dengan demikian, SVR lebih tepat digunakan untuk prediksi jangka pendek yang menuntut kestabilan dan akurasi tinggi, sementara LSTM lebih sesuai untuk prediksi jangka menengah yang membutuhkan sensitivitas terhadap dinamika pasar.

#### DAFTAR PUSTAKA

- [1] R. Luthfiansyah and B. Wasito, "Penerapan Teknik Deep Learning (Long Short Term Memory) dan Pendekatan Klasik (Regresi Linier) dalam Prediksi Pergerakan Saham BRI," *J. Inform. dan Bisnis*, vol. 12, no. 2, pp. 42–54, 2023, doi: 10.46806/jib.v12i2.1059.
- [2] M. Magdalena, A. P. Safira, and I. Maulida, "Penerapan Algoritma Linear Regression Dalam Memprediksi Harga Saham Bank BRI," *J. Sains dan Teknol. Inf.*, vol. 2, no. 3, pp. 88–102, 2024, doi: <https://doi.org/10.62951/switch.v2i3.119>.
- [3] W. C. Utomo, "Prediksi Pergerakan Saham BBRI ditengah Issue Ancaman Resesi 2023 dengan Pendekatan Machine Learning," *J. Teknol. dan Manaj. Inform.*, vol. 9, no. 1, pp. 20–27, 2023, doi: 10.26905/jtmi.v9i1.9135.
- [4] W. Hastomo, Aminudin, and Adhitio Satyo Bayangkari Karno, "Kemampuan Long Short Term Memory Machine Learning Dalam Proyeksi Saham Bank Bri Tbk," *Univ. Gunadarma Jl. Margonda Raya*, vol. 4, no. 1, p. 16424, 2020.
- [5] M. S. Senapan and R. Agustina, "Analisis Fundamental dan Teknikal Saham BCA dan BRI (Tahun 2019-2021)," *Semin. Nas. Akunt. dan Call Pap.*, vol. 3, no. 1, pp. 57–67, 2023, doi: 10.33005/senapan.v3i1.285.
- [6] D. ciptaning Lokiteswara setya wardhani, "Analisis Fundamental Yang Berpengaruh Pada Harga Saham Bank Rakyat Indonesia," *J. Akunt. Bisnis dan Ekon.*, vol. 8, no. 2, pp. 2315–2321, 2023, doi: 10.33197/jabe.vol8.iss2.2022.1385.
- [7] S. Sudriyanto, F. Syahro, and N. Fitriani, "Perbandingan Performa Model Machine Learning Support Vector Machine, Neural Network, Dan K-Nearest Neighbors Dalam Prediksi Harga Saham," *J. Adv. Res. Inform.*, vol. 2, no. 1, pp. 13–21, 2023, doi: 10.24929/jars.v2i1.2983.
- [8] P. Triya, N. Suarna, and N. Dienwati Nuris, "Penerapan Machine Learning Dalam Melakukan Prediksi Harga Saham Pt. Bank Mandiri (Persero) Tbk Dengan Algoritma Linear Regression," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 1, pp. 1207–1214, 2024, doi: 10.36040/jati.v8i1.8958.
- [9] A. W. Ishlah, S. Sudarno, and P. Kartikasari, "Implementasi Gridsearchcv Pada Support Vector Regression (Svr) Untuk Peramalan Harga Saham," *J. Gaussian*, vol. 12, no. 2, pp. 276–286, 2023, doi: 10.14710/j.gauss.12.2.276-286.
- [10] D. I. Puteri, "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah," *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 11, no. 1, pp. 35–43, 2023, doi: 10.34312/euler.v11i1.19791.
- [11] D. M. U. Atmaja and A. R. Hakim, "Peramalan Harga Mata Uang Kripto Solana Menggunakan Metode Support Vector Regression (Svr)," *J. Media Elektro*, vol. XI, no. 2, pp. 97–104, 2022, doi: 10.35508/jme.v0i0.8117.
- [12] A. Khumaidi, R. Raafi'udin, and I. P. Solihin, "Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung," *J. Telemat.*, vol. 15, no. 1, pp. 13–18, 2020, doi: 10.61769/telematika.v15i1.340.
- [13] A. Aulia, B. Aprianti, Y. Supriyanto, and C. Rozikin, "Prediksi Harga Emas dengan Menggunakan Algoritma Support Vector Regression (Svr) dan Linear Regression," *J. Ilm. Wahana Pendidik.*, vol. 8, no. 5, pp. 84–88, 2022, doi: <https://doi.org/10.5281/zenodo.6408864>.
- [14] C. C. Sumarga, D. E. Herwindiati, and J. Hendryli, "Rancangan Sistem Prediksi Harga Saham dengan Menggunakan Metode LSTM dan ARMA klasik," *J. Ilmu Komput. dan Sist. Inf.*, vol. 11, no. 1, 2023, doi: 10.24912/jiksi.v11i1.24075.
- [15] A. Arfan and L. ETP, "Perbandingan Algoritma Long Short-Term Memory dengan SVR Pada Prediksi Harga Saham di Indonesia," *J. Pengkaj. dan Penerapan Tek. Inform.*, vol. 13, no. 1, pp. 33–43, 2020, doi: 10.33322/petir.v13i1.858.
- [16] A. Widianti and I. Pratama, "Penanganan Missing Values Dan Prediksi Data Timbunan Sampah Berbasis Machine Learning," *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 9, no. 2, pp. 242–251, 2024, doi: 10.36341/rabit.v9i2.4789.
- [17] L. M. Ginting, M. M. Sigiyo, E. D. Manurung, and J. J. P. Sinurat, "Perbandingan Metode Algoritma Support Vector Regression dan Multiple Linear Regression Untuk Memprediksi Stok Obat," *J. Appl. Technol. Informatics Indones.*, vol. 1, no. 2, pp. 29–34, 2021, doi: 10.54074/jati.v1i2.36.
- [18] M. Hadi, A. M., Witanti, W., Melina, "Prediksi Pergerakan Harga Emas Menggunakan Metode Genetic Support Vector Regression," *J. Inform. Teknol. dan Sains*, vol. 6, pp. 486–496, 2024, doi: 10.5281/zenodo.6408864.
- [19] A. Hanifa, S. A. Fauzan, M. Hikail, and M. B. Ashfiya, "Perbandingan Metode LSTM dan GRU (RNN) untuk Klasifikasi Berita Palsu Berbahasa Indonesia," *Din. Rekayasa*, vol. 17, no. 1, p. 33, 2021, doi: 10.20884/1.dr.2021.17.1.436.
- [20] 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, 2021, doi: 10.47002/seminastika.v3i1.275.
- [21] W. R. U. Fadilah, D. Agfiannisa, and Y. Azhar, "Analisis Prediksi Harga Saham PT. Telekomunikasi Indonesia Menggunakan Metode Support Vector Machine," *Fountain Informatics J.*, vol. 5, no. 2, p. 45, 2020, doi: 10.21111/fij.v5i2.4449.