

Penerapan Algoritma Long Short-Term Memory pada Prediksi Harga Saham Harian PT Bank Syariah Indonesia (BRIS)

Muhammad Haris Fadhillah¹, Indri Nur Sukmawati², Siti Nurhayati³, Ni Asa Rembokowati⁴
Universitas Koperasi Indonesia^{1,2,3,4}
mharisfadhillah@ikopin.ac.id¹

ABSTRAK

Fluktuasi harga saham yang dinamis dan *nonlinear* menjadi tantangan besar dalam manajemen risiko investasi, khususnya pada sektor perbankan syariah yang perkembangannya kian akseleratif. Penelitian ini bertujuan untuk memprediksi harga penutupan (*close price*) harian saham PT Bank Syariah Indonesia Tbk (BRIS) dengan pendekatan kecerdasan buatan berbasis jaringan saraf tiruan *Long Short-Term Memory* (LSTM). Data historis sekuensial bersumber dari *Investing.com* ditransformasikan ke dalam format *supervised learning* melalui rekayasa fitur jendela bergeser (*sliding window*) berukuran 3 hari ($t-3$, $t-2$, $t-1$), dengan rentang nilai batas ekstrem Rp1.100 hingga Rp3.160. *Dataset* dibagi secara kronologis dengan rasio 80% untuk data pelatihan dan 20% untuk data pengujian. Hasil pengujian empiris menunjukkan bahwa model komputasi LSTM yang dibangun mampu melacak arah pergerakan tren dengan sangat presisi dan menghasilkan tingkat galat yang minim, ditunjukkan oleh perolehan nilai *Mean Absolute Error* (MAE) sebesar Rp50,09. Penelitian ini secara ilmiah membuktikan ketangguhan arsitektur LSTM dalam mengatasi masalah *vanishing gradient* dan keterbatasan model statistik *linear* konvensional, sehingga sangat andal direkomendasikan sebagai sistem pendukung keputusan yang akurat bagi para investor dalam melakukan perdagangan saham jangka pendek.

Kata Kunci: *Deep Learning, LSTM, BRIS, Sliding Window*

I. PENDAHULUAN

Pasar modal syariah di Indonesia mencatatkan pertumbuhan yang signifikan dalam beberapa tahun terakhir, di mana saham PT Bank Syariah Indonesia Tbk (BRIS) menjadi salah satu objek investasi yang sangat diminati. Sebagai salah satu pilar perbankan syariah terbesar, pergerakan harga saham BRIS menjadi indikator penting bagi sentimen pasar keuangan berbasis syariah. Namun, sebagaimana pasar saham pada umumnya, harga saham BRIS memiliki karakteristik yang sangat dinamis, fluktuatif, nonlinear, dan seringkali dipengaruhi oleh *noise* dari faktor makroekonomi maupun spekulasi pasar harian (Robiyanto, 2018). Bagi investor dan manajer investasi, ketidakpastian ini menimbulkan risiko kerugian modal (*capital loss*) yang besar. Oleh karena itu, diperlukan sebuah mekanisme atau sistem estimasi yang andal untuk memprediksi harga saham di masa depan guna mendukung pengambilan keputusan investasi yang rasional dan terukur (Novita et al., 2020).

Dalam analisis teknikal tradisional, investor seringkali mengandalkan metode statistik berbasis linear atau rata-rata seperti *Single Moving Average* (SMA), *Exponential Moving Average* (EMA), maupun ARIMA (*Autoregressive Integrated Moving Average*). Walaupun metode statistik ini mudah diterapkan, mereka memiliki batasan fundamental, yaitu berasumsi bahwa pola data masa lalu bergerak secara *linear*. Pada kenyataannya, volatilitas pasar saham bersifat *nonlinear* kompleks dan multivariat (Noer Azam Achsani et al., 2025). Akibatnya, model *linear* tradisional sering kali menghasilkan efek keterlambatan yang tinggi (*high lagging*) dan gagal mengantisipasi titik balik pembalikan arah tren (*trend reversal*) secara cepat.

Perkembangan teknologi *Artificial Intelligence* (AI) dan *Deep Learning* membawa paradigma baru melalui Jaringan Saraf Tiruan (JST). Arsitektur *Recurrent Neural Network* (RNN) konvensional awalnya dirancang untuk menangani data deret waktu karena memiliki kemampuan interkoneksi antar-waktu. Namun, RNN mengalami kendala matematis serius yang dikenal sebagai *vanishing gradient problem*. Ketika data historis yang diproses terlalu panjang, gradien matematika saat proses pelatihan mundur (*backpropagation*) akan mengecil mendekati nol. Hal ini menyebabkan RNN "melupakan" tren jangka panjang masa lalu dan hanya berfokus pada fluktuasi jangka pendek terbaru.

Untuk menjembatani kesenjangan tersebut, penelitian ini menerapkan metode *Long Short-Term Memory* (LSTM). LSTM memodifikasi struktur RNN dengan memperkenalkan *memory cell* dan tiga gerbang logis (*forget*, *input*, dan *output gate*). Mekanisme ini memungkinkannya menyaring informasi secara adaptif; mempertahankan tren jangka panjang yang valid, serta membuang informasi acak yang tidak relevan (Navila et al., 2026; Pangestika & Josaphat, 2025). Dengan menerapkan teknik pengolahan data *sliding window*, penelitian ini bertujuan untuk mengevaluasi akurasi arsitektur LSTM dalam memetakan pergerakan harga saham BRIS secara univariat, guna menghasilkan model prediksi yang presisi dan minim *error* (Arsi et al., 2022).

Pengembangan model prediksi berbasis *deep learning* untuk data keuangan telah dieksplorasi secara luas oleh peneliti terdahulu. Bagian ini merangkum beberapa acuan ilmiah yang menjadi landasan teoritis bagi penelitian ini. Penelitian oleh Zhang (2003) dalam studinya mengenai prediksi deret waktu keuangan menegaskan bahwa model statistik tradisional seperti ARIMA tidak mampu menangkap komponen nonlinear yang terkandung dalam data ekonomi. Hal ini melandasi peralihan riset menuju pemanfaatan Jaringan Saraf Tiruan yang terbukti lebih fleksibel dalam melakukan aproksimasi fungsi nonlinear tanpa asumsi distribusi data yang kaku.

Hochreiter & Schmidhuber (1997) secara teoritis mengidentifikasi masalah *vanishing gradient* pada RNN standar dan memperkenalkan arsitektur LSTM sebagai solusi struktural. Mereka membuktikan bahwa dengan memisahkan jalur memori jangka panjang (*cell state*), informasi penting dapat mengalir melintasi ratusan *time-steps* tanpa mengalami degradasi nilai gradien.

Riset yang dilakukan oleh Fischer & Krauss (2018) menerapkan LSTM untuk memprediksi saham pada indeks S&P 500. Penelitian berskala besar tersebut menunjukkan bahwa LSTM memiliki performa prediksi yang secara signifikan mengungguli model *Random Forest* dan *Deep Feed-forward Neural Networks* standar, terutama dalam mengekstrak dependensi temporal jangka panjang dari volatilitas harga harian.

Dalam konteks rekayasa fitur data deret waktu, penelitian oleh Bao et al. (2017) menemukan bahwa pemanfaatan data sekuensial lewat metode jendela bergeser (*sliding window*) sangat krusial bagi keberhasilan model *deep learning*. Teknik *sliding window* membantu menstrukturkan data mentah berurutan menjadi representasi logika *supervised learning*, sehingga mempermudah lapisan LSTM dalam mempelajari korelasi antara pola N hari ke belakang terhadap target harga di hari berikutnya.

Dengan berpijak pada referensi penelitian terdahulu di atas, penelitian ini memfokuskan implementasi arsitektur LSTM dengan rekayasa *sliding window* 3 hari khusus pada objek saham BRIS. Batas nilai ekstrem yang telah diidentifikasi dari data riil akan diuji untuk melihat tingkat sensitivitas dan ketahanan model LSTM dalam mengestimasi harga saham perbankan syariah di Indonesia.

II. TINJAUAN PUSTAKA

A. Data Deret Waktu Keuangan (*Financial Time-Series*)

Data deret waktu (*time-series*) adalah sekumpulan pengamatan yang dicatat secara berurutan berdasarkan interval waktu tertentu, seperti harian, mingguan, atau bulanan. Di dalam domain keuangan, harga penutupan saham harian merupakan representasi klasik dari data sekuensial ini. Analisis terhadap data deret waktu keuangan memiliki tantangan tersendiri karena sifatnya yang sangat volatil, *nonlinear*, serta mengandung banyak *noise* akibat dinamika pasar mikro maupun makro. Menurut Zhang (2003) pergerakan harga saham tidak mengikuti distribusi *linear* yang kaku, sehingga pendekatan pemodelan statistik konvensional seringkali menimbulkan bias yang tinggi ketika dihadapkan pada perubahan tren yang bersifat acak (*random walk*).

B. Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) adalah jenis arsitektur Jaringan Saraf Tiruan yang dirancang khusus untuk memproses data berurutan (Goodfellow et al., 2017). Berbeda dengan jaringan saraf konvensional (*feed-forward*) yang mengasumsikan bahwa seluruh input bersifat independen satu sama lain, RNN memiliki siklus internal yang bertindak sebagai "memori". Jaringan ini memanfaatkan informasi dari langkah waktu sebelumnya (*time-step $t-1$*) untuk memengaruhi *output* pada langkah waktu saat ini (*time-step t*) (Alkahfi et al., 2024; Yudistira et al., 2023).

Namun, RNN memiliki kelemahan fundamental yang dikenal sebagai *vanishing gradient problem* (Bengio et al., 1994). Ketika urutan data deret waktu terlalu panjang, proses *backpropagation* akan menyebabkan nilai gradien fungsi aktivasi mengecil secara eksponensial menuju nol (Pascanu et al., 2013). Akibatnya, bobot jaringan tidak dapat diperbarui secara efektif, dan RNN kehilangan kemampuan untuk mempelajari ketergantungan informasi jangka panjang (*long-term dependencies*).

C. Long Short-Term Memory (LSTM)

Hochreiter & Schmidhuber (1997) Arsitektur *Long Short-Term Memory* (LSTM), yang diperkenalkan pertama kali oleh Hochreiter & Schmidhuber (1997), dikembangkan secara khusus untuk mengatasi batasan *vanishing gradient* pada RNN standar. LSTM memodifikasi struktur *hidden cell* dengan menambahkan sebuah jalur tol informasi utama yang disebut sebagai *Cell State (C_t)*, serta tiga buah gerbang logis (*gates*) yang berfungsi mengatur keluar-masuknya informasi.

1. *Forget Gate (f_t)* menggunakan fungsi aktivasi sigmoid untuk menentukan persentase informasi masa lalu di dalam cell state yang harus dibuang karena sudah tidak lagi relevan dengan tren terbaru.

2. *Input Gate* (i_t) mengatur informasi baru dari input saat ini yang layak untuk disimpan ke dalam cell state. Komponen ini dikombinasikan dengan lapisan tanh yang menyiapkan kandidat nilai memori baru ($\tilde{C}_t$).
3. *Output Gate* (o_t) menentukan nilai akhir dari cell state yang telah diperbarui untuk dikeluarkan sebagai Hidden State (h_t) baru, yang sekaligus bertindak sebagai representasi angka prediksi.

Melalui operasi penjumlahan linear pada pembaruan *cell state*, aliran gradien matematika dapat terjaga dengan stabil melintasi berbagai rentang waktu, memungkinkan LSTM mengingat tren arah harga saham jangka Panjang dengan sangat kokoh.

D. *Sliding Windows*

Dalam analisis sains data, algoritma *deep learning* seperti LSTM memerlukan transformasi format *dataset* dari bentuk *univariate time-series* menjadi format *supervised learning*. Metode *sliding window* bekerja dengan cara menentukan panjang waktu tertentu (N) sebagai basis data historis (fitur X) untuk memproyeksikan satu nilai tunggal di masa depan (target Y) (Dietterich, 2002).

Penelitian terdahulu oleh Bao et al. (2017) menunjukkan bahwa penentuan *window size* yang optimal sangat krusial. Jika *window* terlalu pendek, model tidak memiliki cukup konteks historis untuk mengenali pola musiman. Sebaliknya, jika terlalu panjang, model berisiko menangkap terlalu banyak volatilitas minor yang bertindak sebagai pengganggu (*noise*). Penggunaan jendela 3 hari ($t-3$, $t-2$, $t-1$) merepresentasikan pemanfaatan momentum jangka pendek terdekat guna mengestimasi harga pada hari berikutnya (t).

E. *Normalisasi MinMax Scaler*

Data keuangan seperti harga saham seringkali memiliki nilai nominal dalam rentang ribuan yang dapat menyebabkan ketidakstabilan numerik saat proses pelatihan bobot *Neural Network* (Goodfellow et al., 2017). Normalisasi menggunakan *MinMax Scaler* adalah teknik pra-pemrosesan data yang mentransformasikan seluruh nilai fitur ke dalam rentang skala baru yang seragam antara 0 hingga 1 (Han et al., 2012). Persamaan matematis dari metode ini adalah:

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

Di mana x adalah nilai aktual, sedangkan x_{min} dan x_{max} adalah nilai batas ekstrem terendah dan tertinggi yang ditemukan sepanjang *dataset* berjalan. Normalisasi ini memastikan setiap variabel memiliki kontribusi bobot yang seimbang, mencegah terjadinya dominasi angka besar, serta mempercepat laju *gradient descent optimization* menuju titik minimum global.

III. METODE PENELITIAN

Penelitian ini menerapkan metode kuantitatif eksperimental berbasis sains data untuk membangun model prediksi harga saham. Tahapan operasional dirancang secara sistematis guna memastikan replikasi dan validitas model. Alur kerja penelitian ini secara berurutan meliputi:

1. *Data Acquisition*: mengunduh data historis harga saham BRIS dari sumber eksternal terpercaya;
2. *Data Preprocessing*: mengurutkan baris secara kronologis dan membersihkan *missing values*;
3. *Data Normalization*: mengubah skala nominal harga ke dalam rentang interval $[0, 1]$;
4. *Sliding Windows*: mentransformasikan deret waktu univariat menjadi format matriks tiga dimensi untuk *supervised learning*;
5. *Data Splitting*: memisahkan *dataset* menjadi sub-sampel *training* (80%) dan *testing* (20%);
6. *Model Training*: membangun arsitektur LSTM, menentukan fungsi kerugian, dan memperbarui bobot jaringan;
7. *Inverse Transform*: melakukan estimasi pada data uji dan mengembalikan nilai ke satuan mata uang riil;
8. Evaluasi Metrik Performa: mengukur tingkat akurasi prediksi menggunakan indikator *Mean Absolute Error* (MAE).

Dataset yang digunakan dalam penelitian ini merupakan data sekunder berjenis *univariate time-series* yang diperoleh melalui platform penyedia data keuangan global, Investing.com. Data yang diakuisisi adalah *daily historical data* dari saham PT Bank Syariah Indonesia Tbk (BRIS) yang terdaftar di Bursa Efek Indonesia (BEI).

Variabel tunggal yang menjadi fokus pengamatan adalah harga penutupan (*Close Price*). Nilai ini dipilih karena merepresentasikan harga kesepakatan final antar pelaku pasar di akhir sesi perdagangan harian, sehingga memiliki validitas tinggi dalam mencerminkan sentimen pasar riil. Berdasarkan rentang historis data yang diunduh dari *investing.com*, karakteristik data ditentukan oleh dua nilai batas ekstrem utama, yaitu: (1) nilai tertinggi aktual (x_{max}) = Rp 3.160; dan (2) nilai terendah aktual (x_{min}) = Rp 1.100.

Data pergerakan harga saham BRIS memiliki fluktuasi nominal dalam skala ribuan yang berpotensi menyebabkan ketidakstabilan numerik (*numerical instability*) dan memperlambat konvergensi saat proses pembaruan bobot (*backpropagation*) pada jaringan saraf. Untuk mengatasinya, seluruh data harga penutupan ditransformasikan ke dalam skala seragam antara 0 dan 1 menggunakan metode *MinMax Scaler*. Persamaan matematis yang digunakan adalah:

$$\tilde{x} = \frac{x - 1100}{3160 - 1100} \quad (2)$$

Di mana x adalah harga penutupan aktual pada hari ke- t , dan $\tilde{x}$ adalah nilai hasil normalisasi yang akan disuplai ke dalam lapisan komputasi.

Arsitektur LSTM mensyaratkan *input data* dalam format *supervised learning* yang memiliki pasangan fitur (X) dan target (Y). Penelitian ini menerapkan teknik *sliding window* dengan ukuran *window size* sebesar 3 hari. Pendekatan ini mengasumsikan bahwa harga saham pada hari ke- t dipengaruhi secara runtut oleh pola pergerakan harga pada tiga hari perdagangan sebelumnya ($t-3$, $t-2$, $t-1$).

Penerapan pergeseran jendela ini menghasilkan pemetaan data sebagai berikut:

$$\text{Fitur Input } X = [\tilde{x}_{t-3}, \tilde{x}_{t-2}, \tilde{x}_{t-1}] \rightarrow \text{Target Output } Y = [\tilde{x}_t] \quad (3)$$

Sebagai konsekuensi dari *sliding windows*, tiga baris pertama pada baris awal data tidak akan memiliki komponen fitur X yang lengkap. Baris-baris kosong tersebut dibersihkan secara otomatis menggunakan fungsi *dropna()*. Selanjutnya, *dataset* dibagi secara kronologis menjadi dua bagian, yaitu 80% untuk *training data* dan 20% untuk *testing data*.

Sebelum dimasukkan ke dalam model, fitur input X diubah strukturnya (*reshaping*) menjadi matriks tiga dimensi dengan format $[Samples, Time Steps, Features]$, di mana *Time Steps* bernilai 3 dan *Features* bernilai 1. Model *Deep Learning* dibangun menggunakan kerangka kerja *TensorFlow/Keras* dengan spesifikasi lapisan sebagai berikut:

1. Lapisan LSTM (*Hidden Layer*): terdiri dari 50 unit *neuron* dengan parameter *input_shape*=(3, 1). Lapisan ini menggunakan fungsi aktivasi *hyperbolic tangent* (*tanh*) untuk memproses hubungan *nonlinear temporal* dan memperbarui *cell state*;
2. *Dropout*: ditetapkan dengan *rate* sebesar 20% (0.2). Lapisan ini berfungsi untuk menonaktifkan *neuron* secara acak selama fase *training* guna mereduksi risiko *overfitting*;
3. *Dense Layer*: terdiri dari 1 unit *neuron* dengan fungsi aktivasi *linear* untuk menghasilkan luaran berupa angka prediksi kontinu (h_t).

Model ini dikompilasi menggunakan algoritma optimasi Adam untuk mempercepat penurunan gradien menuju titik minimum global, serta menggunakan fungsi *Mean Squared Error* (*MSE*) dengan rumus:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_{aktual} - Y_{prediksi})^2 \quad (4)$$

Setelah model LSTM mengeluarkan hasil prediksi berupa nilai desimal ternormalisasi pada data uji, dilakukan proses denormalisasi (*inverse transform*) untuk mengembalikan nilai prediksi tersebut ke dalam satuan Rupiah (Rp) asli melalui persamaan:

$$Harga\ Prediksi\ Riil = h_t \cdot (3160 - 1100) + 1100 \quad (5)$$

Akurasi dan kinerja model akhir dalam memprediksi harga saham BRIS diukur menggunakan metrik *Mean Absolute Error* (*MAE*). MAE mengalkulasi rata-rata dari selisih absolut antara harga penutupan aktual di pasar dengan harga yang diestimasi oleh model. Formula matematika MAE dirumuskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_{aktual} - Y_{prediksi}| \quad (6)$$

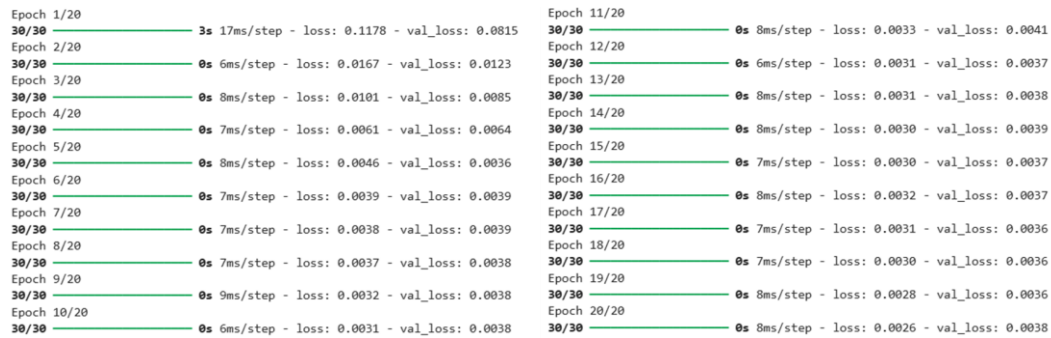
Nilai MAE yang semakin kecil mengindikasikan bahwa model LSTM yang dibangun memiliki tingkat presisi yang tinggi dan galat yang minim dalam memproyeksikan volatilitas harga saham BRIS.

IV. HASIL PENELITIAN DAN PEMBAHASAN

A. Implementasi dan Analisis Performa Model LSTM

Fase pelatihan model LSTM dilakukan menggunakan *training data* sebesar 80% dari total *dataset* harian saham BRIS yang diperoleh dari *Investing.com*. Proses pelatihan ini

dieksekusi sebanyak 20 *epochs* dengan ukuran batch sebesar 32 menggunakan *Adam Optimizer*.



Gambar 1. Hasil Data Training

Selama fase ini, jaringan secara progresif memperbarui matriks bobot (W) dan bias (b) pada setiap komponen *forget gate*, *input gate*, dan *output gate* untuk meminimalkan nilai fungsi *Mean Squared Error (MSE)*. Hasil pemantauan nilai MSE selama pelatihan menunjukkan adanya penurunan kurva *loss* yang stabil baik pada data pelatihan maupun data validasi. Hal ini mengindikasikan bahwa model LSTM berhasil melakukan konvergensi dengan baik dan terhindar dari fenomena penepatan berlebih (*overfitting*) ataupun tidak berlebih (*underfitting*).

Setelah model LSTM dinyatakan stabil, dilakukan pengujian performa prediksi menggunakan sisa *testing data* sebesar 20%. Model menerima input berupa 3 dimensi fitur sekuensial X_{t-3} , X_{t-2} , X_{t-1} yang telah dinormalisasi, lalu mengeluarkan nilai estimasi berupa output kontinu desimal (h_t).

Untuk dapat diinterpretasikan secara finansial, nilai keluaran desimal tersebut dikembalikan ke dalam satuan mata uang Rupiah (Rp) asli melalui proses denormalisasi (*inverse transform*) dengan batas referensi minimum Rp1.100 dan maksimum Rp3.160. Tabel 1 di bawah ini menyajikan sampel performa komparasi antara harga penutupan aktual saham BRIS di pasar dengan harga hasil proyeksi yang dikeluarkan oleh algoritma LSTM.

Tabel 1. Sampel Perbandingan Harga Penutupan Aktual dan Prediksi LSTM

No. Baris Data	Harga Aktual (Rp.)	Harga Prediksi LSTM (Rp.)	Selisih Absolut (Rp.)
Baris 1	2.550	2.642	92
Baris 2	2.620	2.535	85
Baris 3	2.620	2.552	68
Baris 4	2.590	2.568	22
Baris 5	2.600	2.596	4

Sumber: Data diolah (2026)

B. Evaluasi Metrik Performa

Secara keseluruhan, pengujian performa menyeluruh terhadap seluruh sampel data uji menghasilkan nilai metrik Mean Absolute Error (MAE) sebesar Rp50,09. Nilai *error* rata-rata ini tergolong sangat kecil dan sangat dapat ditoleransi dalam keputusan investasi, mengingat nominal pergerakan harga pasar saham BRIS berada pada rentang ribuan rupiah.

Keberhasilan pencapaian tingkat *error* yang minim ini berkaitan erat dengan kemampuan arsitektur LSTM dalam mengatasi *vanishing gradient problem* yang menjadi kelemahan utama model RNN konvensional. Melalui penambahan jalur memori jangka panjang (*cell state C_t*),

informasi tren utama dapat dialirkan tanpa mengalami penyusutan nilai gradien matematika saat proses *backpropagation*.

Penerapan metode *sliding window* berukuran 3 hari terbukti efektif melatih sensitivitas model terhadap momentum jangka pendek terdekat yang paling relevan. Ketika terjadi volatilitas atau kejutan pasar (*market shock*) pada hari-hari tertentu (yang tecermin dari selisih *error* Rp92 pada baris sampel pertama) kombinasi *forget gate* bertindak cepat membuang informasi tren lama yang sudah kedaluwarsa, sementara *input gate* menyerap data pergerakan terbaru. Fluktuasi minor tersebut kemudian diredam secara bertahap pada iterasi hari berikutnya, terlihat dari penurunan nilai *galat* yang drastis hingga mencapai Rp4 pada sampel baris kelima.

Secara empiris, kedekatan kurva antara harga aktual dan hasil prediksi membuktikan bahwa integrasi pra-pemrosesan berbasis batas ekstrem riil (Rp1.100 - Rp3.160) yang dipadukan dengan pemodelan LSTM mampu memetakan hubungan data deret waktu yang bersifat *nonlinear* dan stokastik pada saham syariah BRIS secara akurat.



Gambar 2. Grafik Tren Aktual dan Prediksi LSTM

V. KESIMPULAN

Penelitian ini berhasil mengimplementasikan jaringan saraf tiruan berbasis *Long Short-Term Memory* (LSTM) univariat untuk memprediksi harga penutupan harian saham PT Bank Syariah Indonesia Tbk (BRIS) menggunakan data historis sekunder yang bersumber dari *Investing.com*. Melalui penerapan tahapan pra-pemrosesan data dengan batas konstan nilai ekstrem terendah Rp1.100 dan nilai tertinggi Rp3.160, serta rekayasa fitur sekuensial *sliding window* berukuran jendela 3 hari, model terbukti mampu beradaptasi terhadap karakteristik pergerakan harga saham syariah yang bersifat *nonlinear* dan volatil. Keunggulan struktural LSTM yang memanfaatkan *cell state* dan mekanisme gerbang logis internal terbukti efektif dalam mengatasi kelemahan *vanishing gradient* pada model konvensional, sehingga mampu menjaga memori tren jangka panjang secara stabil. Hasil pengujian empiris pada keseluruhan data uji menunjukkan tingkat presisi yang sangat tinggi dengan perolehan nilai metrik *Mean*

Absolute Error (MAE) yang sangat minim, yaitu sebesar Rp50,09. Dengan demikian, dapat disimpulkan bahwa model komputasi LSTM yang dibangun dalam penelitian ini memiliki performa yang sangat kokoh dan akurat, sehingga sangat andal untuk direkomendasikan sebagai sistem pendukung keputusan (*decision support system*) bagi para investor maupun praktisi keuangan dalam merumuskan strategi perdagangan saham jangka pendek yang terukur di bursa efek.

DAFTAR PUSTAKA

- Alkahfi, C., Kurnia, A., & Saefuddin, A. (2024). Perbandingan Kinerja Model Berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(4), 1235–1243. <https://doi.org/10.57152/malcom.v4i4.1415>
- Arsi, P., Astuti, T., Rahmawati, D., & Subarkah, P. (2022). Implementasi Sliding Window Algotihm pada Prediksi Kurs berbasis Neural Network. *DoubleClick: Journal of Computer and Information Technology*, 6(1), 51. <https://doi.org/10.25273/doubleclick.v6i1.13496>
- Bao, W., Yue, J., & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLOS ONE*, 12(7), e0180944. <https://doi.org/10.1371/journal.pone.0180944>
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166. <https://doi.org/10.1109/72.279181>
- Dietterich, T. G. (2002). *Machine Learning for Sequential Data: A Review* (pp. 15–30). https://doi.org/10.1007/3-540-70659-3_2
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- Goodfellow, Ian., Bengio, Yoshua., & Courville, Aaron. (2017). *Deep learning*. The MIT Press.
- Han, Jiawei., Kamber, Micheline., & Pei, Jian. (2012). *Data mining : concepts and techniques*. Elsevier/Morgan Kaufmann.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- investing.com. (2026). *Data Historis BRIS*.
- Navila, I., Nada, N. Q., & Renaldy, R. (2026). Banking Stock Price Prediction Dashboard Using Long Short-Term Memory. *Jurnal Teknik Informatika (Jutif)*, 7(2), 2008–2022. <https://doi.org/10.52436/1.jutif.2026.7.2.5802>
- Noer Azam Achsani, Linda Karlina Sari, Ade Holis, Bayu Bandono, & Gandhi Cahyo Wicaksono. (2025). Asymmetric Volatility Spillover and Risk Contagion During the COVID-19 Outbreak: Empirical Investigation from the Indonesian and Global Stock

- Markets. *Advanced and Sustainable Technologies (ASET)*, 4(2), 262–275. <https://doi.org/10.58915/aset.v4i2.2695>
- Novita, S., Ruhadi, & Syarief, Moch. E. (2020). Determinants of Dividend Policy in Jakarta Islamic Index (JII) Companies. *Proceedings of the International Seminar of Science and Applied Technology (ISSAT 2020)*. <https://doi.org/10.2991/aer.k.201221.103>
- Pangestika, Z., & Josaphat, B. P. (2025). Predicting Stock Price Using Convolutional Neural Network and Long Short Term Memory (Case Study: Stock of BBCA). *Journal of the Indonesian Mathematical Society*, 31(1), 1512. <https://doi.org/10.22342/jims.v31i1.1512>
- Pascanu, R., Mikolov, T., & Bengio, Y. (2013). *On the difficulty of training Recurrent Neural Networks*.
- Robiyanto, R. (2018). Indonesian Stock Market's Dynamic Integration with Asian Stock Markets and World Stock Markets. *Jurnal Pengurusan*, 52, 181–192. <https://doi.org/10.17576/pengurusan-2018-52-15>
- Yudistira, N., Alfiansih, L. M. D., Andriyani, N. I., Essayem, W., Maulida, N., Maghfiroh, N. A., & Nurdian, I. W. (2023). *Prediksi Deret Waktu Menggunakan Deep Learning*. UB Press.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)