

PREDIKSI HARGA SAHAM PT BANK MANDIRI (PERSERO) TBK PERIODE 2019–2024 MENGGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM) BERBASIS SISTEM WEB

Aldriansyah Abdillah¹, Marah Doly Nasution²
al.abdillah2506@gmail.com¹, marahdoly@umsu.ac.id²
Universitas Muhammadiyah Sumatera Utara

ABSTRAK

Pasar modal merupakan indikator penting perekonomian nasional, di mana volatilitas harga saham menuntut ketersediaan metode prediksi yang presisi untuk mendukung pengambilan keputusan investasi yang rasional. Penelitian ini bertujuan merancang, membangun, dan mengevaluasi model prediksi harga saham PT Bank Mandiri (Persero) Tbk (BMRI) periode 2019–2024 menggunakan arsitektur Long Short-Term Memory (LSTM), serta mengintegrasikannya ke dalam sistem berbasis web untuk mendukung reproduksibilitas dan aksesibilitas hasil penelitian. Data yang digunakan adalah data sekunder deret waktu univariat berupa harga penutupan harian (closing price) yang diperoleh dari Yahoo Finance. Metode penelitian mencakup prapemrosesan data (Min-Max Scaling), pembentukan data sekuensial dengan teknik sliding window, pembagian data secara kronologis dengan rasio 80:20, serta pengujian beberapa skenario hyperparameter. Hasil penelitian menunjukkan bahwa konfigurasi model terbaik dicapai pada arsitektur 2 layer LSTM dengan 50 neuron per layer, look-back window 30 hari, dropout rate 0,2, dan 50 epoch pelatihan, dengan optimizer Adam dan fungsi kerugian Mean Squared Error. Model tersebut menghasilkan nilai Root Mean Square Error (RMSE) sebesar 173,17, Mean Absolute Error (MAE) sebesar 139,09, dan Mean Absolute Percentage Error (MAPE) sebesar 2,13% yang termasuk kategori sangat akurat (excellent). Hasil ini membuktikan bahwa arsitektur LSTM yang diimplementasikan pada sistem berbasis web efektif dan andal dalam memprediksi pola pergerakan harga saham BMRI secara akurat, konsisten, dan dapat direproduksi.

Kata Kunci: BMRI; Deep Learning; Long Short-Term Memory; Prediksi Harga Saham; Sistem Berbasis Web.

ABSTRACT

The capital market is a key indicator of national economic performance, where volatile stock price movements require precise prediction methods to support rational investment decision-making. This study aims to design, build, and evaluate a stock price prediction model for PT Bank Mandiri (Persero) Tbk (BMRI) for the 2019–2024 period using a Long Short-Term Memory (LSTM) architecture, and to integrate it into a web-based system to support the reproducibility and accessibility of the research results. The data used is univariate time series secondary data in the form of daily closing prices obtained from Yahoo Finance. The research method includes data preprocessing (Min-Max Scaling), sequential data formation using a sliding window technique, chronological data splitting with an 80:20 ratio, and testing of several hyperparameter scenarios. The results show that the best model configuration is achieved with a 2-layer LSTM architecture of 50 neurons per layer, a 30-day look-back window, a 0.2 dropout rate, and 50 training epochs, using the Adam optimizer and Mean Squared Error loss function. The model produced a Root Mean Square Error (RMSE) of 173.17, a Mean Absolute Error (MAE) of 139.09, and a Mean Absolute Percentage Error (MAPE) of 2.13%, classified as an excellent accuracy category. These results demonstrate that the LSTM architecture implemented within a web-based system is effective and reliable for predicting BMRI stock price movements accurately, consistently, and reproducibly.

Keywords: BMRI; Deep Learning; Long Short-Term Memory; Stock Price Prediction; Web-Based System.

PENDAHULUAN

Pasar modal merupakan salah satu pilar fundamental dalam pembangunan ekonomi suatu negara, termasuk Indonesia, karena menjadi jembatan yang mempertemukan pihak yang memiliki kelebihan dana (surplus unit) dengan pihak yang membutuhkan modal (deficit unit) untuk pengembangan usaha (Bakhri, 2018). Harga saham tidak hanya mencerminkan kinerja fundamental perusahaan penerbitnya, tetapi juga menjadi indikator ekspektasi pasar terhadap prospek ekonomi nasional, sehingga kemampuan memprediksi harga saham menjadi aspek krusial bagi investor, analis, maupun regulator dalam menyusun strategi pengambilan keputusan yang rasional dan berbasis data (Septiani et al., 2020). PT Bank Mandiri (Persero) Tbk (BMRI), sebagai salah satu bank BUMN dengan kapitalisasi pasar terbesar di Indonesia, mencatatkan pergerakan harga yang sangat dinamis pada periode 2019–2024 — mulai dari penguatan sebelum pandemi, tekanan tajam akibat pandemi COVID-19 pada tahun 2020, hingga pemulihan dan koreksi pascapandemi (Karnadi & Fahmi, 2021) — sehingga diperlukan pendekatan analitis yang mampu menangkap pola hubungan kompleks dan ketergantungan jangka panjang dalam data tersebut.

Perkembangan deep learning menghadirkan solusi alternatif dalam prediksi data deret waktu (time series) yang bersifat nonlinear dan volatil, mengingat metode statistik konvensional seperti ARIMA dan GARCH kerap tidak mampu menangkap pola yang kompleks secara optimal (Zaheer et al., 2023). Salah satu arsitektur yang populer digunakan adalah Long Short-Term Memory (LSTM), yang diperkenalkan oleh Hochreiter dan Schmidhuber (1997) sebagai varian Recurrent Neural Network (RNN) untuk mengatasi permasalahan vanishing gradient dan exploding gradient yang membatasi kemampuan RNN standar dalam mempelajari ketergantungan jangka panjang (Bengio et al., 1994). Melalui mekanisme forget gate, input gate, dan output gate, LSTM mampu menyimpan informasi relevan dalam jangka panjang sekaligus mengabaikan informasi yang tidak signifikan, sehingga sangat sesuai untuk menganalisis data harga saham yang bersifat sekuensial dan memiliki ketergantungan temporal kuat (Gajamannage & Park, 2022).

Beberapa penelitian terdahulu memperkuat validitas pendekatan ini. Lara-Benítez et al. (2021) membuktikan secara eksperimental bahwa LSTM menghasilkan prediksi paling akurat di antara tujuh arsitektur deep learning yang diuji pada lebih dari 50.000 deret waktu. Zaheer et al. (2023) menunjukkan bahwa pendekatan berbasis LSTM mampu menghasilkan akurasi prediksi yang tinggi pada data saham yang volatil, dengan variasi hyperparameter memberikan pengaruh signifikan terhadap kualitas prediksi. Pada konteks pasar modal Indonesia, Budiprasetyo et al. (2022) memperoleh MAPE terbaik sebesar 1,51% untuk prediksi harga saham Kalbe Farma menggunakan LSTM 8 layer, sementara Gajamannage dan Park (2022) menegaskan bahwa kemampuan LSTM dalam menyimpan memori internal jangka panjang menjadikannya sangat sesuai untuk data pasar keuangan yang kompleks dan volatil, baik pada saham, cryptocurrency, maupun komoditas. Secara konsisten, studi-studi tersebut menunjukkan bahwa konfigurasi hyperparameter — khususnya jumlah layer dan neuron — berpengaruh signifikan terhadap kualitas prediksi LSTM, dan bahwa RMSE, MAE, serta MAPE merupakan metrik evaluasi standar yang digunakan dalam bidang ini.

Meskipun demikian, penelitian yang secara spesifik menganalisis saham BMRI pada periode 2019–2024 — rentang yang mencakup kondisi pra-pandemi, krisis pandemi

COVID-19, fase pemulihan, hingga normalisasi pascapandemi — masih relatif terbatas. Sebagian besar penelitian sejenis juga berhenti pada tahap eksperimen berbasis notebook (script-based) dan belum diintegrasikan ke dalam sistem yang dapat diakses, ditelusuri, dan direproduksi secara terstruktur. Penelitian ini berkontribusi mengisi kesenjangan tersebut dengan (1) mengevaluasi performa LSTM secara spesifik pada saham BMRI melalui rentang waktu yang mencakup kondisi pasar yang sangat beragam, dan (2) mengintegrasikan model terbaik ke dalam sistem berbasis web yang mengotomatisasi manajemen dataset, konfigurasi eksperimen, serta penyimpanan artefak model demi menjamin reproduksibilitas hasil. Penelitian ini bertujuan untuk merancang, membangun, dan mengevaluasi model prediksi harga saham BMRI menggunakan pendekatan LSTM berdasarkan data closing price historis, mengukur performanya menggunakan metrik RMSE, MAE, dan MAPE, serta mengimplementasikan model terbaik ke dalam sistem berbasis web yang fungsional.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimental dan bersifat prediktif. Pendekatan kuantitatif diterapkan karena penelitian berfokus pada pengolahan data numerik berupa harga penutupan harian (closing price) saham BMRI periode 2019–2024, sedangkan pendekatan eksperimental diterapkan melalui tahapan perancangan, pelatihan, pengujian, dan evaluasi model prediksi menggunakan metode LSTM. Alur penelitian secara umum meliputi pengumpulan data, prapemrosesan, pembagian data, perancangan dan pelatihan model, pengujian, evaluasi, hingga implementasi hasil ke dalam sistem berbasis web.

HASIL DAN PEMBAHASAN

Hasil Skenario Eksperimen dan Pemilihan Model Terbaik

Dua skenario eksperimen utama diuji untuk melihat pengaruh perubahan look-back window, jumlah layer LSTM, dan jumlah epoch terhadap performa model. Tabel 1 menyajikan konfigurasi dan hasil evaluasi masing-masing skenario berdasarkan dataset yang mencakup keseluruhan periode hingga Desember 2024.

Tabel 1. Hasil Evaluasi Performa Model Berdasarkan Skenario Eksperimen

Parameter / Metrik	Eksperimen 1	Eksperimen 2
Look-back window	30 hari	60 hari
Jumlah layer LSTM	2 layer	3 layer
Jumlah neuron per layer	50	50
Epoch	50	100
Batch size	32	32
Learning rate	0,001	0,001
Dropout rate	0,2	0,2
RMSE (Rp)	173,17	174,99
MAE (Rp)	139,09	139,48
MAPE (%)	2,13	2,13
Kategori (Lewis, 1982)	Excellent	Excellent

Meskipun kedua skenario menghasilkan nilai MAPE yang identik (2,13%), Eksperimen 1 ditetapkan sebagai model terbaik karena menghasilkan nilai RMSE dan

MAE yang lebih rendah dibandingkan Eksperimen 2. Temuan ini mengindikasikan berlakunya prinsip parsimoni (Occam's razor) dalam pemodelan deret waktu keuangan: arsitektur yang lebih ringkas (2 layer, look-back 30 hari, 50 epoch) mampu menyamai atau melampaui performa arsitektur yang lebih kompleks (3 layer, look-back 60 hari, 100 epoch), sekaligus menunjukkan bahwa penambahan kapasitas model tidak selalu berbanding lurus dengan peningkatan akurasi prediksi.

Evaluasi Performa Model Terbaik

Berdasarkan pengujian terhadap 1.469 baris data uji, model terbaik (Eksperimen 1) menghasilkan nilai RMSE sebesar Rp173,17, MAE sebesar Rp139,09, dan MAPE sebesar 2,13%. Merujuk pada skala interpretasi Lewis (1982), nilai MAPE tersebut termasuk ke dalam kategori sangat akurat (excellent, $\leq 10\%$), yang menunjukkan bahwa secara rata-rata penyimpangan harga hasil prediksi hanya bergeser sekitar 2,13% dari harga penutupan aktual. Jarak yang relatif sempit antara nilai MAE dan RMSE turut mengindikasikan bahwa kesalahan prediksi model terdistribusi secara konsisten dan tidak didominasi oleh penyimpangan ekstrem pada observasi tertentu.


Perbandingan Harga Aktual dan Prediksi

Tabel 2 menyajikan cuplikan perbandingan antara harga aktual dan harga hasil prediksi model terbaik pada beberapa hari perdagangan terakhir Desember 2024, setelah nilai keluaran model dikembalikan ke skala harga asli melalui proses denormalisasi.

Tabel 2. Cuplikan Perbandingan Harga Aktual dan Prediksi Model Terbaik

Tanggal Observasi	Harga Aktual (Rp)	Harga Prediksi (Rp)	Selisih Absolut (Rp)
19 Desember 2024	5.800	5.920	120
20 Desember 2024	5.750	5.885	135
23 Desember 2024	5.750	5.830	80
27 Desember 2024	5.800	5.815	15
30 Desember 2024	5.700	5.810	110

Gambar 1 memvisualisasikan hasil tersebut secara menyeluruh pada seluruh periode pengujian. Garis prediksi (putus-putus) secara umum mengikuti arah pergerakan garis harga aktual, termasuk pada tren kenaikan yang terjadi pada kuartal ketiga 2024 maupun tren penurunan tajam menjelang akhir tahun. Pola ini konsisten dengan cara kerja forget gate pada arsitektur LSTM, yang secara selektif mempertahankan informasi tren jangka panjang sekaligus meredam pengaruh fluktuasi harian yang bersifat sementara (noise) terhadap hasil prediksi (Hochreiter & Schmidhuber, 1997). Selain prediksi pada data uji, sistem juga menghasilkan forecast satu hari perdagangan berikutnya (H+1): berdasarkan harga penutupan aktual terakhir sebesar Rp5.700 pada 30 Desember 2024, model memproyeksikan harga penutupan berikutnya sebesar Rp5.810.



Gambar 1. Perbandingan Harga Aktual dan Prediksi pada Data Pengujian (Model Terbaik)

Signifikansi Penalaan Hyperparameter

Penambahan kompleksitas model pada Eksperimen 2 — berupa satu layer LSTM tambahan (dari 2 menjadi 3 layer), perpanjangan look-back window (dari 30 menjadi 60 hari), serta penggandaan jumlah epoch (dari 50 menjadi 100) — pada praktiknya tidak memberikan peningkatan akurasi, bahkan menghasilkan RMSE dan MAE yang sedikit lebih tinggi dibandingkan Eksperimen 1. Temuan ini sejalan dengan hasil Budiprasetyo et al. (2022) yang menunjukkan bahwa jumlah layer LSTM memengaruhi kualitas prediksi secara signifikan, namun pengaruh tersebut tidak selalu berbanding lurus — penambahan kapasitas model perlu diimbangi dengan kesesuaian terhadap karakteristik data yang dianalisis. Pada data harga saham BMRI periode 2024 yang menunjukkan volatilitas dan pembalikan arah (reversal) yang relatif cepat, look-back window yang lebih pendek (30 hari, setara sekitar satu setengah bulan perdagangan) tampak menjadi titik optimal yang memberikan model keleluasaan untuk merespons perubahan tren baru secara lebih cepat, sedangkan look-back window yang lebih panjang (60 hari) cenderung membebani model dengan informasi historis yang sebagian sudah tidak relevan terhadap kondisi pasar terkini.

Implementasi dan Efektivitas Sistem Berbasis Web

Transformasi model dari lingkungan eksperimen berbasis notebook menjadi sistem perangkat lunak terintegrasi terbukti berhasil mengotomatisasi keseluruhan alur kerja, mulai dari manajemen dataset dan konfigurasi skenario eksperimen hingga penyimpanan artefak model dan hasil evaluasi ke dalam basis data. Pengujian fungsional (black-box testing) terhadap mekanisme autentikasi dan pembatasan hak akses antara peran admin dan pengguna menunjukkan bahwa seluruh skenario pengujian berjalan sesuai dengan hasil yang diharapkan. Dengan penyimpanan artefak model (.keras) dan objek scaler (.pkl) berbasis ID eksperimen, sistem memungkinkan hasil penelitian ditelusuri dan digunakan kembali tanpa memerlukan pelatihan ulang, sehingga turut mendukung prinsip reproduksibilitas penelitian ilmiah. Meskipun demikian, pengujian responsivitas antarmuka pada resolusi tablet dan perangkat mobile masih menunjukkan sejumlah kendala tampilan yang perlu disempurnakan pada pengembangan berikutnya.

Keterbatasan Penelitian

Penelitian ini memiliki sejumlah keterbatasan yang perlu diperhatikan dalam menginterpretasikan hasilnya. Pertama, pendekatan univariat yang hanya mengandalkan closing price membuat model tidak dapat menangkap pengaruh guncangan makroekonomi, sentimen pasar, maupun faktor fundamental perusahaan secara langsung, sehingga seluruh proyeksi murni didasarkan pada pola historis pergerakan harga. Kedua, proses pelatihan model pada sistem web saat ini masih bersifat synchronous terhadap permintaan HTTP, sehingga pengguna perlu menunggu proses pelatihan selesai sebelum antarmuka dapat digunakan kembali; pada volume data penelitian ini (sekitar 1.250 baris), kondisi tersebut masih berada dalam batas toleransi waktu tunggu, namun berpotensi menjadi kendala apabila diterapkan pada volume data maupun jumlah epoch yang jauh lebih besar.

KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan beberapa hal sebagai berikut. Pertama, model prediksi harga saham BMRI berhasil dibangun menggunakan data sekunder publik periode 2019–2024 yang diperoleh dari Yahoo Finance, dengan pemanfaatan data yang secara etis dan hukum dapat dipertanggungjawabkan berdasarkan Undang-Undang Nomor 14 Tahun 2008 tentang Keterbukaan Informasi Publik dan Undang-Undang Nomor 28 Tahun 2014 tentang Hak Cipta. Kedua, konfigurasi model

terbaik dicapai pada arsitektur 2 layer LSTM dengan 50 neuron per layer, dropout rate 0,2, look-back window 30 hari, dan 50 epoch pelatihan, yang menghasilkan nilai RMSE sebesar Rp173,17, MAE sebesar Rp139,09, dan MAPE sebesar 2,13% — termasuk kategori sangat akurat (excellent) berdasarkan skala Lewis (1982) — pada pengujian terhadap 1.469 baris data uji. Ketiga, temuan ini menegaskan berlakunya prinsip parsimoni dalam pemodelan deret waktu keuangan, di mana arsitektur yang lebih ringkas terbukti lebih tangguh dan gesit dalam merespons volatilitas pasar dibandingkan arsitektur yang lebih kompleks. Keempat, model terbaik berhasil diintegrasikan secara penuh ke dalam sistem berbasis web yang mengotomatisasi manajemen dataset, konfigurasi eksperimen, serta penyimpanan artefak model secara terstruktur, sehingga mendukung reproduksibilitas dan aksesibilitas hasil penelitian bagi pengguna.

Penelitian selanjutnya disarankan untuk mengembangkan pendekatan multivariat dengan menambahkan parameter eksternal seperti volume perdagangan, Indeks Harga Saham Gabungan (IHSG), suku bunga acuan, nilai tukar Rupiah, maupun analisis sentimen berita guna meningkatkan kepekaan model terhadap guncangan makroekonomi. Dari sisi rekayasa perangkat lunak, arsitektur backend sistem web disarankan dikembangkan ke arah pelatihan model asynchronous (misalnya menggunakan Celery atau Redis) untuk mengantisipasi skala data dan epoch yang lebih besar di masa mendatang, serta pengembangan fitur sinyal keputusan (trading signal) berbasis ambang toleransi risiko agar sistem lebih aplikatif bagi praktisi pasar modal.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara atas dukungan akademik selama penelitian ini dilaksanakan.

DAFTAR PUSTAKA

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M., Levenberg, J., Mané, D., Monga, R., Moore, S., Murray, D., Olah, C., Schuster, M., Shlens, J., Steiner, B., Sutskever, I., Talwar, K., Tucker, P., Vanhoucke, V., Vasudevan, V., Viégas, F., Vinyals, O., Warden, P., Wattenberg, M., Wicke, M., Yu, Y., & Zheng, X. (2015). TensorFlow: Large-scale machine learning on heterogeneous systems. Software available from tensorflow.org.
- Bakhri, S. (2018). Investasi dan pasar modal. Jakarta: Pustaka Pelajar.
- 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>
- Budiprasetyo, G., Hani'ah, M., & Aflah, D. Z. (2022). Prediksi harga saham syariah menggunakan algoritma Long Short-Term Memory (LSTM). *Jurnal Nasional Teknologi dan Sistem Informasi*, 8(3), 164–172. <https://doi.org/10.25077/TEKNOSI.v8i3.2022.164-172>
- Chollet, F., et al. (2015). Keras. GitHub. <https://github.com/fchollet/keras>
- Gajamannage, K., & Park, Y. (2022). Real-time forecasting of time series in financial markets using sequentially trained many-to-one LSTMs. *arXiv preprint arXiv:2205.04678*. <https://doi.org/10.48550/arXiv.2205.04678>
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451–2471. <https://doi.org/10.1162/089976600300015015>
- Grinberg, M. (2018). Flask web development: Developing web applications with Python. O'Reilly Media, Inc.
- 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>

- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). Melbourne: OTexts.
- Karnadi, A., & Fahmi, I. (2021). Analisis kinerja keuangan perusahaan perbankan (Studi kasus pada PT Bank Mandiri Tbk). *Jurnal Ekonomi dan Keuangan*, 9(1), 45–56.
- Lara-Benítez, P., Carranza-García, M., & Riquelme, J. C. (2021). An experimental review on deep learning architectures for time series forecasting. *International Journal of Neural Systems*, 31(3), 2130001. <https://doi.org/10.1142/S0129065721300011>
- Lewis, C. D. (1982). *Industrial and business forecasting methods*. London: Butterworths.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Septiani, M., Ariyanto, D., & Wibowo, A. (2020). Pengaruh literasi keuangan dan persepsi risiko terhadap keputusan investasi di pasar modal. *Jurnal Akuntansi dan Keuangan*, 12(2), 88–98.
- Yahoo Finance. (2026). PT Bank Mandiri (Persero) Tbk (BMRI.JK) historical data. Diakses dari <https://finance.yahoo.com/quote/BMRI.JK/history>
- Zaheer, S., Anjum, N., Hussain, S., Algarni, A. D., Iqbal, J., Bourouis, S., & Ullah, S. S. (2023). A multi parameter forecasting for stock time series data using LSTM and deep learning model. *Mathematics*, 11(3), 590. <https://doi.org/10.3390/math11030590>