

Implementation of LSTM for Gold Price Prediction in Indonesia

Maria Oktaviani Giska Sibannang ^{1*}, I Gusti Lanang Wijayakusuma ^{2*}

^{*} Matematika, Universitas Udayana

sibannang.2208541074@student.unud.ac.id ¹, lanang_wijaya@unud.ac.id ²

Article Info

Article history:

Received 2025-11-26

Revised 2026-01-09

Accepted 2026-01-17

Keyword:

*Time Series,
LSTM,
MAPE,
MSE,
Prediction,
Gold Price.*

ABSTRACT

Gold is a significant investment instrument that serves as a safe-haven asset; nevertheless, its price dynamics are inherently nonlinear and highly volatile due to the influence of various economic factors. This study aims to develop a predictive model for daily gold prices denominated in Indonesian Rupiah. The proposed methodology employs a Long Short-Term Memory (LSTM) neural network architecture. Historical gold price data covering the period from January 1, 2015, to October 1, 2025, were obtained from investing.com. The dataset underwent a preprocessing phase, which included normalization using the MinMaxScaler and the construction of input sequences with a sliding window of 60 time steps. The implemented LSTM model consists of two stacked layers, each comprising 16 units, and is equipped with a dropout rate of 0.2 as well as an early stopping mechanism to improve generalization and prevent overfitting. The evaluation results demonstrate that the proposed model achieved a Mean Absolute Percentage Error (MAPE) of 5.08% and an accuracy of 94.92%, with a Mean Squared Error (MSE) of 0.00203. Furthermore, the visualization of prediction outcomes confirms the model's capability to effectively capture actual price fluctuations, including during periods of heightened market volatility. Overall, these findings indicate that a relatively simple LSTM architecture is effective for forecasting gold price movements in the Indonesian market. The results of this study provide a robust foundation for the future development of more sophisticated predictive systems and potential real-time applications.



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

I. PENDAHULUAN

Emas telah lama diakui sebagai instrumen investasi yang penting dan aset safe-haven karena kemampuannya mempertahankan nilai, terutama selama periode ketidakpastian ekonomi, dan juga dijadikan sebagai aset produksi perhiasan dan keuangan mengingat nilai penyimpanannya yang tinggi [1], [2]. Maka dari itu prediksi emas haruslah akurat agar dapat membantu memberi keuntungan pada para investor dan informasi yang baik pada regulator pasar. Tetapi karena pasar emas memiliki sifat yang nonlinear, harga emas dan volume perdagangannya di pasar rentan terhadap berbagai faktor dan menghasilkan fluktuasi yang besar [3].

Di masa awal pandemi COVID-19 (Maret 2020), harga emas berfluktuasi antara Rp726 ribu dan Rp860 ribu per gram, lalu terus mengalami variasi hingga menyentuh Rp808 ribu per gram pada akhir November 2020. Ketidakstabilan ini

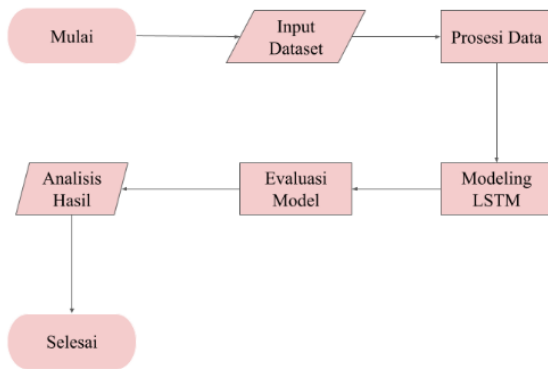
membuat suatu model yang mampu memprediksi harga emas masa depan menjadi sangat diperlukan untuk dijadikan fondasi dalam pengambilan keputusan investasi [4]. Prediksi merupakan suatu kegiatan yang memperkirakan keadaan pada masa mendatang berdasarkan masa lalu [5]. Beberapa metode telah digunakan untuk memprediksi data deret waktu, termasuk metode statistik seperti ARIMA. Tetapi meskipun metode statistik seperti ARIMA telah dipakai secara luas dalam prediksi data deret waktu, keterbatasannya terletak pada kemampuannya hanya meramalkan periode jangka pendek [6].

Celah penelitian (Research Gap) ini memotivasi para peneliti untuk beralih ke teknik machine learning yang lebih fleksibel. Di antara berbagai algoritma, Artificial Neural Network (ANN) telah menunjukkan kinerja yang menjanjikan. Khususnya, arsitektur Long Short-Term Memory (LSTM) yang pada dasarnya dikembangkan sebagai solusi atas keterbatasan vanishing gradient. Sehingga,

arsitektur ini sangat efektif dalam mengenali dan mempelajari hubungan serta pola yang kompleks dalam data deret waktu untuk jangka panjang [7]. Studi oleh [Diqi et al, 2024] dan [Zakka dan Emigawaty, 2025] yang diterapkan telah menunjukkan keberhasilan dalam memperkirakan pergerakan harga saham dengan ketepatan yang tinggi [8], [9].

Berbeda dengan penelitian sebelumnya yang umumnya mengusulkan model hibrida kompleks seperti ARIMA–LSTM, CNN–LSTM, atau GRU dengan banyak parameter, penelitian ini secara khusus berfokus pada evaluasi kinerja model LSTM tunggal yang berarsitektur sederhana dalam memprediksi harga emas harian di Indonesia.

Kontribusi utama yang diharapkan pada penelitian ini adalah: (1) memberikan evaluasi empiris terhadap efektivitas LSTM berdiri sendiri pada data harga emas domestik dalam Rupiah, (2) menunjukkan bahwa arsitektur sederhana dengan jumlah parameter terbatas tetap mampu mencapai tingkat kesalahan prediksi yang rendah, dan (3) menyediakan baseline yang kuat bagi pengembangan model yang lebih kompleks pada penelitian selanjutnya. Dengan demikian, penelitian ini tidak berfokus pada kompleksitas arsitektur, melainkan pada validasi kemampuan minimal model LSTM dalam menangkap pola temporal jangka panjang pada pasar emas Indonesia.



Gambar 1. Proses Pelatihan Model LSTM

II. METODE

Rangkaian tahapan yang membentuk penelitian ini terdiri dari pengambilan data, pemrosesan, penerapan model, evaluasi, hingga analisis hasil. Diagram alur yang digunakan dalam pelaksanaan studi ini dapat dilihat pada Gambar 1.

A. Data Penelitian

Dalam penelitian ini, data yang dianalisis berupa data harga emas harian yang mencakup periode sejak 1 Januari 2015 sampai dengan 1 Oktober 2025. Data bersifat tabular dan diambil dari situs website investing.com dalam bentuk csv. Dataset ini memuat enam variabel utama, meliputi Tanggal, Harga Terakhir, Harga Pembukaan, Harga Tertinggi, dan Harga Terendah.

B. Prosesi Data

Sebelum membangun model LSTM, dilakukan preprocessing data dengan menghapus kolom ‘Vol.’ dan ‘Perubahan %’, mengkonversi tanggal ke format datetime, serta mengubah data numerik menjadi float. Data kemudian diperiksa untuk memastikan tidak ada duplikasi atau missing values. Selanjutnya dilakukan normalisasi menggunakan MinMaxScaler pada kolom harga penutupan untuk mengubah nilai ke rentang [0,1], karena LSTM sensitif terhadap skala data. Rumus normalisasi yang digunakan adalah:

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Dimana X adalah data asli, X_{min} dan X_{max} masing-masing adalah nilai minimum dan maksimum dari data [10]. Data time series kemudian diubah menjadi sequence dengan panjang 60 time steps, sehingga tiap sampel menggunakan 60 hari sebelumnya untuk memprediksi hari ke-61. Setelah itu, data di-reshape ke bentuk 3D [samples, time steps, features] agar sesuai dengan input LSTM.

C. Model LSTM

Long Short-Term Memory (LSTM) Adalah varian yang lebih mutakhir dari Recurrent Neural Network (RNN), yang secara khusus dikembangkan untuk menangani kelemahan mendasar RNN dalam menangkap hubungan atau dependensi jangka panjang [11]. Arsitektur ini pertama kali diperkenalkan pada tahun 1997 [12]. Arsitektur LSTM dibuat secara khusus untuk mengatasi persoalan vanishing dan exploding gradient yang sering muncul pada RNN, khususnya saat jaringan harus mengenali hubungan atau informasi yang berlangsung dan tersimpan dalam rentang waktu yang panjang. Dengan keunggulan tersebut, LSTM menjadi pilihan yang tepat untuk berbagai tugas prediksi maupun klasifikasi pada data deret waktu (time-series). Secara umum, arsitektur LSTM tersusun atas tiga bagian utama, yaitu lapisan masukan (input layer), lapisan tersembunyi (hidden layers), dan lapisan keluaran (output layer) [13].

D. Evaluasi Model

Penilaian kinerja model dilakukan dengan dua metrik utama, yakni Mean Absolute Percentage Error (MAPE) dan Mean Squared Error (MSE). MAPE memberikan kesalahan dalam persentase, yang mudah diinterpretasi, sedangkan MSE memberikan kesalahan dalam satuan asli data. Kedua metrik dihitung untuk data training dan testing.

Persamaan yang digunakan untuk menentukan nilai Mean Squared Error (MSE) ditunjukkan di bawah ini:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Dimana \hat{y}_i adalah nilai prediksi dan y_i adalah nilai aktual, dan n menunjukkan jumlah keseluruhan data. Mean Squared Error (MSE) adalah metrik populer dalam statistik dan

machine learning untuk menilai keakuratan model regresi. Prinsip dasar metrik ini adalah mengukur rata-rata selisih kuadrat antara nilai yang diprediksi dan nilai sebenarnya, untuk memberikan gambaran mengenai tingkat kesalahan prediksi model secara umum [14].

MAPE (Mean Absolute Percentage Error) dihitung dalam dua langkah: kesalahan absolut dibagi nilai observasi (aktual) pada setiap periode, dan hasilnya dirata-ratakan untuk mendapatkan persentase absolut. Metrik MAPE bertujuan untuk mengukur tingkat penyimpangan (error) dalam bentuk persentase antara data hasil peramalan dan data observasi aktual (Sari & Hasanuddin, 2020). Formula perhitungan RMSE dapat dinyatakan melalui persamaan berikut:

$$MAPE = \left(\frac{1}{n}\right) \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i}$$

Nilai MAPE dapat diinterpretasikan berdasarkan skala penilaian yang dikemukakan oleh Lewis. Skala tersebut membagi tingkat akurasi prediksi ke dalam beberapa kategori, seperti yang ditunjukkan pada Tabel 1.

TABEL 1.
KATEGORI MAPE

Nilai MAPE	Keterangan
MAPE < 10%	Sangat Akurat
10% ≤ MAPE < 20%	Baik
20% ≤ MAPE < 50%	Normal
MAPE ≤ 50%	Tidak Akurat

Evaluasi kinerja model prediksi ditentukan oleh besaran nilai MAPE yang didapat, dengan menggunakan skala yang telah ditetapkan tersebut. Kriteria utama penilaian adalah: semakin rendah nilai MSE dan MAPE yang dihasilkan, maka semakin tinggi tingkat akurasi model dalam melakukan prediksi, karena nilai prediksi menjadi semakin mendekati data observasi aktual [15].

E. Skema Evaluasi Model

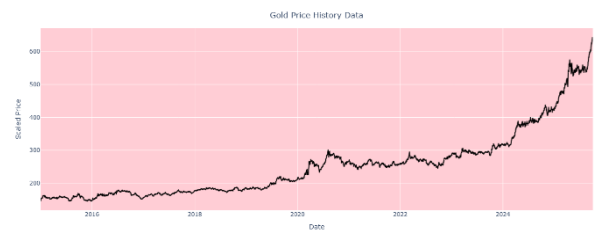
Pembagian data dilakukan menggunakan time-based split untuk menjaga urutan kronologis data deret waktu. Data periode Januari 2015 hingga Desember 2024 digunakan sebagai data pelatihan, sedangkan data Januari 2025 hingga Oktober 2025 digunakan sebagai data pengujian.

Pendekatan ini dipilih karena lebih realistis dibandingkan pembagian acak (random split) dan sesuai dengan skenario prediksi dunia nyata, di mana model dilatih pada data historis dan diuji pada periode masa depan.

Selain itu, proses pelatihan divalidasi menggunakan validation set internal yang dipantau melalui metrik validation loss untuk mendeteksi overfitting, dengan mekanisme early stopping.

III. HASIL DAN PEMBAHASAN

Penelitian ini memanfaatkan data yang diunduh melalui situs investing.com, dengan rentang waktu dari 01 Januari 2015 hingga 01 Oktober 2025. Visualisasi data historis ini disajikan dalam bentuk grafik pada Gambar 2. Jumlah data yang digunakan adalah sebanyak 2805 data. Pada tahap selanjutnya dalam proses pengolahan data awal (data preprocessing) adalah pemisahan data menjadi set pelatihan (training) dan set pengujian (testing). Sebanyak 2485 data digunakan untuk training, 260 data digunakan dalam testing, dan time-step sebanyak 60. Gambar 2 menunjukkan pembagian data pelatihan dan data pengujian berdasarkan waktu.



Gambar 2. Grafik Harga Emas



Gambar 3. Training and Test Set

Tahap selanjutnya dilakukan proses normalisasi data dengan memanfaatkan metode MinMaxScaler, yang menskalakan nilai data ke rentang [0, 1]. Normalisasi ini wajib dilakukan karena sensitivitas model LSTM terhadap skala data, sekaligus untuk mencegah fitur skala besar mendominasi proses pelatihan [16]. Selain itu, normalisasi membantu dalam mempercepat konvergensi selama proses training [17]. Normalisasi dilakukan pada kolom 'Terakhir' (harga penutupan) yang menjadi target prediksi. Lima data sebelum dan sesudah normalisasi dapat dilihat pada Tabel 2.

TABEL 2.
PERBANDINGAN DATA SEBELUM DAN SESUDAH NORMALISASI

Sebelum	Sesudah
146.282	0.002007
148.928	0.007322
152.018	0.013529
154.176	0.017863
154.254	0.018002

Model deep learning yang diaplikasikan adalah jaringan Long Short-Term Memory (LSTM). Model terdiri atas dua lapisan LSTM berurutan, masing-masing dengan 16 unit memori. Lapisan pertama LSTM dikonfigurasi dengan `return_sequences=True` untuk mempertahankan urutan waktu dan meneruskan informasi ke lapisan berikutnya, sedangkan lapisan kedua mengembalikan vektor keadaan akhir. Guna mengurangi kemungkinan overfitting, konfigurasi arsitektur yang digunakan adalah dengan menempatkan lapisan Dropout yang memiliki laju sebesar 0,2 setelah setiap lapisan LSTM. Lapisan output berupa Dense Tunggal dengan fungsi aktivasi linear untuk menghasilkan prediksi harga. Model dikompilasi dengan optimizer Adam, menggunakan Mean Squared Error (MSE) baik sebagai fungsi loss maupun metrik evaluasi. Untuk mencegah overfitting selama pelatihan, digunakan callback Early Stopping yang memantau `val_loss` dengan patience 5 epoch.

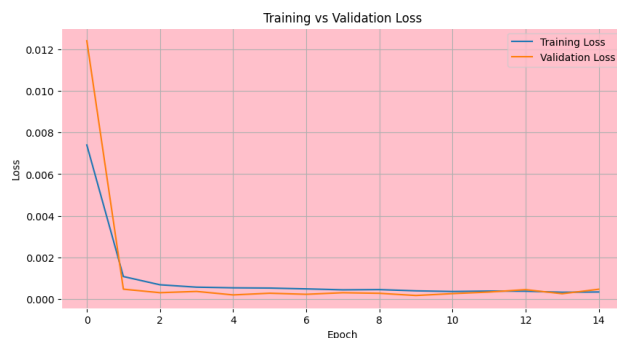
TABEL 3. RINGKASAN ARSITEKTUR MODEL BESERTA JUMLAH PARAMETER TIAP LAYER

Layer (Tipe)	Output Shape	Parameter
lstm 1 (LSTM)	(None, 60, 16)	1,152
dropout 1 (Dropout)	(None, 60, 16)	0
lstm 2 (LSTM)	(None, 16)	2,112
dropout 2 (Dropout)	(None, 16)	0
dense (Dense)	(None, 1)	17
Total Parameter		3,281

Arsitektur model LSTM yang diimplementasikan menggunakan pendekatan stacked LSTM dua lapis dengan konfigurasi yang optimal untuk data deret waktu harga emas. Lapisan pertama LSTM terdiri dari 16 unit dengan `return_sequences=True` untuk mempertahankan struktur sekuensial data dan meneruskan informasi temporal secara lengkap ke lapisan berikutnya. Lapisan kedua LSTM dengan 16 unit menghasilkan representasi fitur temporal yang terkonsentrasi sebelum diproses lebih lanjut.

Setiap lapisan LSTM diikuti oleh Dropout layer dengan rate 0.2 yang berfungsi sebagai mekanisme regularisasi untuk mencegah overfitting dengan cara menonaktifkan secara acak 20% neuron selama proses training. Arsitektur ini diakhiri dengan lapisan Dense tunggal dengan fungsi aktivasi linear yang berperan sebagai output layer untuk menghasilkan prediksi nilai harga.

Total parameter model sebanyak 3,281 menunjukkan efisiensi komputasi yang tinggi dibandingkan model LSTM konvensional, sementara tetap mempertahankan kapasitas untuk mempelajari pola temporal kompleks. Penerapan Early Stopping dengan patience 5 epoch pada monitor `val_loss` memastikan proses training berhenti secara otomatis ketika model sudah mencapai konvergensi optimal, sehingga mencegah overtraining dan mengoptimalkan penggunaan sumber daya komputasi. Secara empiris, arsitektur ini menunjukkan konvergensi pelatihan yang stabil dan generalisasi yang baik terhadap data validasi, Tabel 3 menunjukkan ringkasan arsitektur model LSTM.



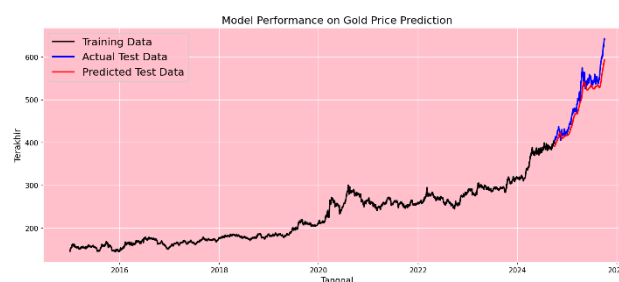
Gambar 4. Training VS Validation Loss

Analisis kurva training loss dan validation loss pada Gambar 4 menunjukkan pola penurunan yang konsisten dan konvergen tanpa divergensi signifikan, yang mengindikasikan bahwa model tidak mengalami overfitting. Penerapan dropout dan early stopping terbukti efektif dalam menjaga kemampuan generalisasi model meskipun menggunakan data jangka panjang.

TABEL 4.
HASIL EVALUASI MODEL LSTM

Metrik	Nilai
MSE	0.0020302634220570326
MAPE	0.050817313127757134
Accuracy	0.9491826868722428

Hasil evaluasi menunjukkan bahwa model LSTM dua lapis menghasilkan nilai MAPE sebesar 5,08%, yang termasuk dalam kategori sangat akurat berdasarkan kriteria Lewis. Nilai ini mengindikasikan bahwa rata-rata kesalahan prediksi berada pada kisaran 5% dari harga aktual, yang relatif kecil untuk data finansial yang bersifat volatil.



Gambar 5. Plot Hasil Data Prediksi VS Aktual

Gambar 5. menampilkan perbandingan antara nilai aktual dan hasil prediksi harga emas pada data pengujian. Garis berwarna biru merepresentasikan nilai harga emas aktual, sedangkan garis merah menggambarkan hasil prediksi yang diperoleh dari model LSTM. Secara visual, model mampu mengikuti arah tren dan fluktuasi harga emas dengan baik, terutama pada fase tren naik dan stabil. Namun, pada beberapa titik ekstrem seperti lonjakan tajam harga, masih terlihat deviasi prediksi. Hal ini menunjukkan keterbatasan model berbasis harga historis murni dalam merespons kejutan pasar yang dipicu oleh faktor eksternal non-teknis. Temuan

ini mengindikasikan bahwa meskipun LSTM sederhana memiliki performa yang kuat, integrasi variabel makroekonomi atau penggunaan pendekatan hibrida berpotensi meningkatkan ketahanan model terhadap periode volatilitas tinggi.

Penelitian ini memiliki beberapa keterbatasan. Pertama, model hanya menggunakan data harga historis tanpa memasukkan variabel fundamental seperti inflasi, nilai tukar, atau harga emas global, sehingga respons model terhadap kejadian ekonomi eksternal masih terbatas.

Kedua, evaluasi dilakukan pada satu konfigurasi arsitektur LSTM tanpa perbandingan langsung dengan model baseline seperti ARIMA atau SVR, sehingga keunggulan relatif model belum dapat diklaim secara komparatif.

Ketiga, analisis performa belum difokuskan secara khusus pada subperiode krisis atau volatilitas ekstrem, yang berpotensi menjadi arah pengembangan penelitian selanjutnya.

IV. KESIMPULAN

Melalui penelitian ini, ditetapkan bahwa model Long Short-Term Memory (LSTM) memiliki kapabilitas untuk memprediksi harga emas di Indonesia dengan tingkat akurasi yang tinggi. Model Long Short-Term Memory (LSTM) dengan arsitektur dua lapis yang dikembangkan dalam penelitian ini telah berhasil menunjukkan efektivitasnya dalam memprediksi harga emas harian dalam Rupiah. Model yang relatif sederhana ini mencapai kinerja yang sangat baik dengan nilai MAPE sebesar 5.08% yang tergolong dalam kategori "sangat akurat" menurut kriteria Lewis. Arsitektur yang efisien dengan total 3.281 parameter terbukti mampu menangkap pola temporal yang kompleks dari data historis harga emas, didukung oleh penerapan mekanisme regularisasi dropout dan early stopping yang berhasil mencegah overfitting dan memastikan konvergensi model yang stabil. Hasil visualisasi prediksi terhadap data aktual memperkuat temuan ini, menunjukkan kemampuan model dalam mengikuti pola fluktuasi harga termasuk pada periode volatilitas tinggi, meskipun terdapat deviasi minor pada beberapa titik tertentu. Penelitian ini menunjukkan bahwa model LSTM berarsitektur sederhana mampu memberikan performa prediksi yang kompetitif untuk harga emas di Indonesia. Namun, hasil ini tidak dimaksudkan untuk menggantikan model kompleks, melainkan sebagai baseline empiris bagi pengembangan penelitian lanjutan.

DAFTAR PUSTAKA

- [1] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "Prediksi Harga Emas Menggunakan Metode LSTM dan GRU," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, Aug. 2023, doi: 10.23960/jitet.v11i3.3250.
- [2] D. Rahmadani, "The Role of Gold as a Safe Haven Asset in Risk Management Strategies in the Era of Geopolitical and Monetary Uncertainty," doi: <https://dx.doi.org/10.2139/ssrn.5338848>.
- [3] Y. Lin, R. Wu, Y. Yue, and Q. Liao, "Forecasting gold price using a novel hybrid model with MEEMD-convLSTM CReditT authorship contribution statement," doi: <https://dx.doi.org/10.2139/ssrn.4591257>.
- [4] A. Mulya Hadi, W. Witanti, J. Informatika, and U. Jenderal Achmad Yani, "Agustus 2024 486 Prediksi Pergerakan Harga Emas Menggunakan Metode Genetic Support Vector Regression," *Jurnal Informatika Teknologi dan Sains*, doi: <https://doi.org/10.51401/jinteks.v6i3.4247>.
- [5] A. K. Azis and K. Kustanto, "Penerapan Moving Average Pada Prediksi Penjualan Accu," *Jurnal Teknologi Informasi dan Komunikasi (TIKOMSiN)*, vol. 11, no. 1, p. 25, Apr. 2023, doi: 10.30646/tikomsin.v11i1.722.
- [6] J. Cahyani, S. Mujahidin, and T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 11, no. 2, p. 346, Jul. 2023, doi: 10.26418/justin.v11i2.57395.
- [7] S. Joddy, "Comparative Analysis of CNN, LSTM, and CNN-LSTM for Indonesian Stock Prediction," vol. 7, no. 3, pp. 283–289, 2025, doi: 10.21512/emacsjournal.v6.
- [8] M. Diqi, I. Wayan Ordiyasa, and R. Yogyakarta, "Enhancing Stock Price Prediction Using Stacked Long Short-Term Memory," *Journal Research and Development (ITJRD)*, vol. 8, no. 1, 2024, doi: 10.25299/itjrd.2024.13486.
- [9] M. Syukron Zakka, "Stock Price Prediction Using Deep Learning (LSTM) with a Recursive Approach," 2025. doi: <https://doi.org/10.30871/jaic.v9i5.10514>.
- [10] M. Sholeh, D. Andayati, R. Yuliana Rachmawati, P. Studi Informatika, and F. Teknologi Informasi dan Bisnis, "Data Mining Model Klasifikasi Menggunakan Algoritma K-Nearest Neighbor Dengan Normalisasi Untuk Prediksi Penyakit Diabetes Data Mining Model Classification Using Algorithm K-Nearest Neighbor With Normalization For Diabetes Prediction," doi: 10.36342/teika.v12i02.2911.
- [11] M. Khairunisa, D. Made Sidantya Amanda Putri, and I. Gusti Ngurah Lanang Wijayakusuma, "Comparison of Machine Learning Methods for Menstrual Cycle Analysis and Prediction," 2025. doi: <https://doi.org/10.30871/jaic.v9i2.9076>.
- [12] M. Kamal Wisyaldin, G. Maya Luciana, H. Pariaman, and P. Pembangkitan Jawa Bali, "Pendekatan Long Short-Term Memory untuk Memprediksi Kondisi Motor 10 kV pada PLTU Batubara," vol. 9, no. 2, doi: 10.33322/kilat.v9i2.997.
- [13] R. Al Kiramy, I. Permana, A. Marsal, M. R. Munzir, and M. Megawati, "Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT. Hajar Aswad," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1224–1234, Jul. 2024, doi: 10.57152/malcom.v4i4.1373.
- [14] H. H. Nuha, "Mean Squared Error (MSE) dan Penggunaannya," doi: 10.2139/ssrn.4420880.
- [15] M. Mushliha, "Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia," *Jambura Journal of Mathematics*, vol. 6, no. 2, pp. 195–203, Aug. 2024, doi: 10.37905/jjom.v6i2.26509.
- [16] P. Anjarwati and P. Widyaningsih, "Raw Material Stock Prediction Using the Long Short-Term Memory Algorithm (Case Study: Mizan and Sunan Grilled Bread Producers)," *Journal of Artificial Intelligence and Software Engineering*, vol. 5, no. 3, pp. 1296–1308, 2025, doi: 10.30811/jaise.v5i3.7199.
- [17] R. Ihza Yuzar Vianda, P. Anjarwati, H. Akbar Pratama, R. Maulana Akbar, and R. Dwi Irawan, "Klasifikasi Citra Bunga Multikelas Menggunakan Convolutional Neural Network (CNN)," *Seminar Nasional Teknologi Informasi dan Bisnis (SENATIB)*, p. 2025, doi: <https://doi.org/10.47701/0d10j421>.