

Forecasting Harga EUR/USD Harian Menggunakan Long Short-Term Memory (LSTM) Berbasis Log Return

^{1*}Erwin Setiawan, ²Wahyu Cahyo Utomo, ³Danang Wahyu Widodo

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹erwinsetyawan37@gmail.com, ²wahyu.utomo@unpkdr.ac.id,
³danangwahyuwidodo@unpkediri.ac.id

³danangwahyuwidodo@unpkediri.ac.id
Penulis Korespondens : Erwin Setiawan

Abstrak—Penelitian ini mengkaji penerapan jaringan saraf Long Short-Term Memory (LSTM) untuk meramalkan nilai tukar EUR/USD harian pada periode 2015–2024. Model menggunakan harga Open, High, Low, dan Close (OHLC) yang telah ditransformasi secara logaritmik sebagai fitur input, dengan log harga penutupan hari berikutnya sebagai target prediksi. Delapan konfigurasi LSTM dengan variasi jumlah unit (64 dan 128), jumlah *layer* (1 dan 2), serta *dropout rate* (0,2 dan 0,3) dievaluasi secara sistematis menggunakan *Root Mean Square Error* (RMSE) dan *Directional Statistic* (Dstat). Metrik Dstat didefinisikan dalam konteks trading prediksi dianggap benar apabila model secara tepat memperkirakan arah pergerakan harga penutupan esok hari relatif terhadap harga penutupan hari ini. Fungsi *Huber loss* diterapkan untuk memastikan ketahanan model terhadap data pencilan. Eksperimen dilakukan dengan pembagian data *train-test* 70:30, di mana *StandardScaler* hanya di-fit pada *data training* guna mencegah kebocoran data (*data leakage*). Hasil menunjukkan bahwa konfigurasi terbaik (C2: 64 unit, 1 layer, *dropout*=0,3) mencapai *Test RMSE* sebesar 0,006780 dan *Test Dstat* sebesar 53,04%, sementara seluruh konfigurasi secara konsisten melampaui *baseline* acak 50%. Analisis mengkonfirmasi kecenderungan *underfitting* pada konfigurasi berlapis lebih dalam (C4, C8) serta generalisasi yang baik pada model *single-layer*.

Kata Kunci—LSTM, EUR/USD, Log Return, RMSE, Directional Statistic, Forex Forecasting

Abstract— This study examines the application of Long Short-Term Memory (LSTM) neural networks to forecast the daily EUR/USD exchange rate over the period 2015–2024. The model employs logarithmically transformed Open, High, Low, and Close (OHLC) prices as input features, with the log closing price of the following day as the prediction target. Eight LSTM configurations varying in the number of units (64 and 128), number of layers (1 and 2), and dropout rate (0.2 and 0.3) are systematically evaluated using Root Mean Square Error (RMSE) and Directional Statistic (Dstat). The Dstat metric is defined in a trading context: a prediction is considered correct when the model accurately anticipates the direction of the next day's closing price movement relative to the current day's closing price. Huber loss is applied to ensure model robustness against outliers. Experiments are conducted with a 70:30 train-test data split, where StandardScaler is fitted exclusively on the training data to prevent data leakage. Results indicate that the best-performing configuration (C2: 64 units, 1 layer, dropout=0.3) achieves a Test RMSE of 0.006780 and a Test Dstat of 53.04%, while all configurations consistently surpass the random baseline of 50%. The analysis confirms an underfitting tendency in deeper multi-layer configurations (C4, C8) and good generalization in single-layer models.

Keywords—LSTM, EUR/USD, Log Return, RMSE, Directional Statistic, Forex Forecasting

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Pasar valuta asing (*foreign exchange / forex*) merupakan pasar keuangan besar dan yang paling likuid di dunia. [1]. Di antara berbagai pasangan mata uang, EUR/USD adalah pasangan yang paling likuid dan paling banyak diperdagangkan secara global. Kemampuan memprediksi arah pergerakan harga EUR/USD memiliki nilai strategis tinggi bagi pelaku pasar, manajer risiko, maupun pengembang sistem perdagangan otomatis.

Prediksi deret waktu keuangan merupakan permasalahan yang sangat menantang karena sifatnya yang non-linear, non-stasioner, serta dipengaruhi berbagai faktor makroekonomi yang kompleks. Pendekatan statistik klasik seperti ARIMA memiliki keterbatasan dalam menangkap kompleksitas pasar *forex* [2]. Di sisi lain, metode pembelajaran mesin multivariat telah terbukti mampu mengidentifikasi sinyal krisis dengan akurasi yang lebih superior dibandingkan indikator pasar tunggal tradisional [3]. Seiring perkembangan deep learning, *Long Short-Term Memory* (LSTM) varian dari *Recurrent Neural Network* (RNN) telah terbukti unggul dalam memodelkan dependensi jangka panjang pada data sekuensial [4].

Beberapa penelitian telah mengeksplorasi penggunaan LSTM untuk prediksi *forex*. Model LSTM mampu memprediksi harga *forex* EUR/USD dengan nilai RMSE sebesar 0,038 dan MAPE sebesar 2,5%, dengan *goodness-of-fit* R^2 mencapai 97% pada dataset penuh [5]. Perbandingan mendalam LSTM dan GRU pada pasangan EUR/USD menunjukkan bahwa LSTM secara konsisten menghasilkan akurasi prediksi yang lebih stabil meskipun GRU menawarkan waktu pelatihan lebih singkat [6]. Model LSTM *multi-layer* juga terbukti mampu menangkap tren pelemahan dan penguatan nilai tukar dengan kekeliruan minimal sekaligus adaptif terhadap guncangan pasar jangka pendek [7].

Pengembangan arsitektur lebih lanjut turut dieksplorasi dalam berbagai studi. Arsitektur *Two-Layer Stacked LSTM* dengan analisis korelasi fitur terbukti mempercepat konvergensi dan mengurangi galat prediksi [8]. Integrasi LSTM dengan *Temporal Convolutional Network* (TCN) dalam arsitektur hibrida LSTM-TCN menghasilkan *Test RMSE* terbaik sebesar 0,003911 pada pasangan EUR/USD, AUD/USD, dan GBP/USD [9]. Model berbasis mekanisme *attention* yang digabungkan dengan LSTM mampu mencapai estimasi *annual return* sebesar 8,79%–19% dalam simulasi perdagangan nyata [10].

Dari perspektif metrik evaluasi, *Directional Statistic* (Dstat) telah diperkenalkan sebagai ukuran kemampuan prediksi arah pergerakan harga dalam konteks pengambilan keputusan trading, di mana prediksi yang benar ditentukan berdasarkan kesesuaian arah relatif terhadap harga aktual hari ini [11]. Dari sisi karakteristik distribusi data, distribusi *log return* pasar valuta asing secara konsisten memiliki sifat ekor gemuk (*heavy-tailed*), eksesi kurtosis, dan *clustering* volatilitas [12] sehingga fungsi *loss* yang robust terhadap pencilan seperti *Huber loss* menjadi sangat relevan [13].

Penelitian ini bertujuan untuk membangun model LSTM dengan fitur log-transformasi OHLC untuk memprediksi harga penutupan EUR/USD harian, mengevaluasi delapan konfigurasi model secara sistematis menggunakan RMSE dan Dstat, serta menganalisis kemampuan model dalam memprediksi arah pergerakan harga untuk kebutuhan pengambilan keputusan trading. Kontribusi utama terletak pada penerapan definisi Dstat berbasis konteks trading [11] yang secara langsung mencerminkan keputusan nyata: prediksi dianggap benar apabila model tepat memperkirakan apakah harga penutupan esok hari akan lebih tinggi atau lebih rendah dari harga penutupan hari ini.

II. METODE

A. Pengumpulan Data

Data yang digunakan adalah harga OHLC (*Open, High, Low, Close*) harian EUR/USD selama periode 1 Januari 2015 hingga 31 Desember 2024, diperoleh dari Yahoo Finance melalui library *yfinance*. Total terdapat 2.610 hari perdagangan. Data dibagi tanpa pengacakan (*no shuffle*) menjadi set pelatihan (*train*) sebesar 70% mencakup periode 2015–2021, dan set pengujian (*test*) sebesar 30% mencakup periode 2022–2024.




Gambar 1. Harga Penutupan Harian EUR/USD 2015–2024

Gambar 1 menyajikan pergerakan harga penutupan harian EUR/USD sepanjang periode 2015–2024. Terlihat tren penurunan jangka panjang dari kisaran 1,20 pada 2015 menuju level paritas (mendekati 1,00) pada pertengahan 2022, diikuti pemulihan bertahap sepanjang 2023 dan konsolidasi pada 2024.


B. Analisis Data Eksploratif (EDA)

Log return harian didefinisikan sebagai $r_t = \ln(C_t/C_{t-1})$, di mana C_t adalah harga penutupan pada hari ke- t . Hasil analisis distribusi menunjukkan bahwa *log return* EUR/USD memiliki karakteristik *leptokurtik* dengan *kurtosis excess* = 2,613, yaitu distribusi dengan ekor lebih tebal dari distribusi normal.



Gambar 2. Distribusi Log Return Harian EUR/USD dan Q-Q Plot. Mean = -5.70×10^{-5} , Std = 0.0050, Kurtosis excess = 2.613.

Gambar 2 menunjukkan distribusi *log return* EUR/USD yang *leptokurtik* dengan *kurtosis excess* 2,613, yaitu berpuncak lebih tinggi dan berekor lebih tebal dibanding distribusi normal. Q-Q Plot di sebelah kanan memperkuat temuan tersebut, ditandai titik-titik pada kedua ekor yang menyimpang dari garis normal.



Gambar 3. ACF dan PACF Log Return Harian EUR/USD. Seluruh Lag Berada di Dalam Confidence Band, Mengindikasikan Sifat White Noise.

Gambar 3 memperlihatkan seluruh lag ACF dan PACF dari 1 hingga 40 berada di dalam confidence band 95%, sehingga tidak terdapat autokorelasi yang signifikan. Pola ini mengindikasikan sifat *white noise* pada *log return* yang konsisten dengan *Efficient Market Hypothesis* (EMH).

C. Feature Engineering dan Preprocessing

Empat fitur input dibentuk melalui transformasi logaritmik: $\log_open = \ln(Open)$, $\log_high = \ln(High)$, $\log_low = \ln(Low)$, $\log_close = \ln(Close)$. Target prediksi adalah $\log_next_close = \ln(Close_{t+1})$. Normalisasi menggunakan *StandardScaler* yang di-fit secara eksklusif pada *data training*, kemudian diterapkan hanya di *transform* pada data *test*. Prosedur ini kritis untuk mencegah *data leakage* di mana informasi statistik data *test* tidak boleh bocor ke proses pelatihan.

D. Arsitektur Model LSTM

Model LSTM dibangun dengan pendekatan *sliding window lookback* sebesar 30 hari. Setiap sampel input $X \in \mathbb{R}^{30 \times 4}$ merepresentasikan 30 hari terakhir dari keempat fitur log-OHLC, sementara target $y \in \mathbb{R}$ adalah $\log_next_close$ hari ke-31. Delapan konfigurasi model dievaluasi dengan variasi jumlah unit LSTM (64 dan 128), jumlah *layer* (1 dan 2), serta *dropout rate* (0,2 dan 0,3), sebagaimana ditampilkan pada Tabel 1.

Tabel 1. Delapan Konfigurasi LSTM yang Diuji

Config	Units	Layers	Dropout	LR	Loss Fn	Lookback	Batch
C1	64	1	0.2	0.001	Huber	30	32
C2	64	1	0.3	0.001	Huber	30	32
C3	64	2	0.2	0.001	Huber	30	32
C4	64	2	0.3	0.001	Huber	30	32
C5	128	1	0.2	0.001	Huber	30	32
C6	128	1	0.3	0.001	Huber	30	32
C7	128	2	0.2	0.001	Huber	30	32
C8	128	2	0.3	0.001	Huber	30	32

Seluruh model dikompilasi dengan optimizer Adam (*learning rate* = 0,001) dan *Huber loss function*. Pelatihan menggunakan *EarlyStopping* (*patience* = 20, monitor *val_loss*, *restore_best_weights* = *True*) dan *ReduceLROnPlateau* (*factor* = 0,5, *patience* = 10, *min_lr* = 1×10^{-6}) untuk mencegah *overfitting* dan memastikan konvergensi optimal.

E. Metrik Evaluasi

RMSE (*Root Mean Square Error*) mengukur akurasi prediksi nilai harga dalam skala asli setelah *inverse log-transform*:

$$RMSE = \sqrt{(1/n \cdot \sum(\hat{y}_i - y_i)^2)} \dots\dots\dots(1)$$

Directional Statistic (Dstat) didefinisikan dalam konteks trading: prediksi dianggap benar (*hit*) apabila model secara tepat memprediksi arah pergerakan harga penutupan esok hari relatif terhadap harga penutupan aktual hari ini:

$$Dstat = (1/n) \cdot \sum \mathbb{I}[\text{sign}(y_i - c_i) = \text{sign}(\hat{y}_i - c_i)] \times 100\% \dots\dots\dots(2)$$

di mana c_t adalah harga penutupan aktual hari ini (referensi), y_t adalah harga penutupan aktual esok hari, dan $\hat{y}_t$ adalah harga penutupan prediksi esok hari. Nilai Dstat > 50% mengindikasikan kemampuan prediksi arah yang lebih baik dari tebakan acak.

III. HASIL DAN PEMBAHASAN


A. Perbandingan 8 Konfigurasi LSTM

Tabel 2. Hasil Evaluasi 8 Konfigurasi LSTM (Urut *Test Dstat* Tertinggi)

Rank	Config	Units	Layers	Dropout	Epoch	Train RMSE	Test RMSE	Train Dstat	Test Dstat
1	C2	64	1	0.3	164	0.006480	0.006780	51.30%	53.04%
2	C5	128	1	0.2	112	0.006331	0.007139	49.75%	53.04%
3	C1	64	1	0.2	127	0.006398	0.006757	50.36%	52.78%
4	C7	128	2	0.2	118	0.006376	0.007475	50.03%	52.65%
5	C6	128	1	0.3	132	0.006447	0.006772	50.81%	52.52%
6	C3	64	2	0.2	91	0.006454	0.007754	50.92%	52.52%
7	C4	64	2	0.3	120	0.006564	0.009136	50.75%	51.36%
8	C8	128	2	0.3	92	0.006523	0.009077	50.53%	51.23%

Catatan: konfigurasi terbaik berdasarkan Test Dstat tertinggi

Dari Tabel 2, seluruh delapan konfigurasi berhasil melampaui *baseline* acak 50% pada *Test Dstat*, dengan rentang 51,23%–53,04%. Konfigurasi C2 (64 unit, 1 *layer*, *dropout* = 0,3) dan C5 (128 unit, 1 *layer*, *dropout* = 0,2) mencapai *Test Dstat* tertinggi sebesar 53,04%. Dari sisi RMSE, C1 dan C2 menunjukkan performa terbaik dengan nilai 0,006757 dan 0,006780 secara berturut-turut. Terdapat pola konsisten: konfigurasi dua *layer* (C4 dan C8) menunjukkan *Test RMSE* jauh lebih tinggi (0,009136 dan 0,009077), mengindikasikan kecenderungan *underfitting* pada arsitektur lebih dalam dengan dataset yang tersedia.




Gambar 4. Perbandingan RMSE (kiri) dan Dstat (kanan) antara set train dan test untuk semua konfigurasi.

Gambar 4 menyajikan perbandingan visual nilai RMSE (panel kiri) dan Dstat (panel kanan) pada *set train* dan *test* untuk kedelapan konfigurasi. Pada panel kiri, selisih RMSE *train-test* relatif kecil pada konfigurasi satu *layer* (C1, C2, C5, C6), sedangkan konfigurasi dua *layer* (C4 dan C8) memperlihatkan lonjakan RMSE *test* yang mencolok sebagai indikasi menurunnya kemampuan generalisasi. Pada panel kanan, seluruh konfigurasi memiliki Dstat *test* di atas garis *baseline* acak 50%, dengan C2 dan C5 berada pada posisi tertinggi. Visualisasi ini mempertegas temuan Tabel 2 bahwa penambahan kedalaman arsitektur tidak serta-merta meningkatkan akurasi, melainkan justru memperbesar galat pada data uji

B. Analisis Aktual vs Prediksi


C.



Gambar 5. Actual vs. Predicted EUR/USD untuk Konfigurasi Terbaik pada Set Test (2022–2024).

Gambar 5 memperlihatkan bahwa konfigurasi C2 LSTM berhasil mengikuti tren makro harga EUR/USD dengan baik, termasuk penurunan tajam menuju paritas pada pertengahan 2022, pemulihan bertahap sepanjang 2023, dan konsolidasi di 2024. Namun demikian, terdapat *time-lag* yang terlihat pada mayoritas konfigurasi prediksi cenderung tertinggal satu langkah dibandingkan pergerakan aktual, yang merupakan karakteristik umum model LSTM pada data keuangan yang *highly efficient*.


D. Analisis Loss Curve dan Konvergensi
E.



Gambar 6. Loss curve training (biru) dan validasi (merah) untuk 8 konfigurasi LSTM

Gambar 6 menampilkan kurva *Huber loss data training* (biru) dan validasi (merah) untuk kedelapan konfigurasi, seluruh model berkonvergensi dengan penurunan loss yang mulus tanpa lonjakan, menandakan proses pelatihan yang stabil. Nilai *validation loss* konsisten berada di bawah *training loss* efek wajar dari *dropout* yang aktif saat pelatihan namun nonaktif saat validasi sementara konfigurasi dua layer (C3, C4, C7, C8) konvergen lebih cepat (91–120 *epoch*) dibandingkan C2 yang membutuhkan *epoch* terbanyak (164).

F. Analisis Overfitting
G.




Gambar 7. RMSE Ratio (train/test) dan Gap Dstat (|train – test |) sebagai Indikator Overfitting

Gambar 7 menunjukkan konfigurasi C1, C2, C5, C6, dan C7. *RMSE Ratio* mendekati 1,0 (rentang 0,887–0,956), mengindikasikan good fit. Konfigurasi C4 dan C8 memiliki *RMSE Ratio* terendah (0,718–0,719), yang dalam konteks ini menunjukkan *underfitting*: arsitektur dua layer yang dikombinasikan dengan *dropout* tinggi (0,3) terlalu membatasi kapasitas pembelajaran model, sehingga model gagal menangkap pola data secara memadai yang berujung pada performa

test yang *inferior*. Gap Dstat terbesar terjadi pada C5 (3,29%), sementara C4 memiliki gap terkecil (0,61%).

H. Detail Konfigurasi Terbaik (C2)

I.



Gambar 8. Detail plot konfigurasi terbaik C2 (64 units, 1 layer, dropout=0.3): Actual Vs Predicted, Zoom 120 Hari Terakhir, Loss Curve, Residual, Directional Scatter, dan Rolling Dstat 30-bar.

Konfigurasi C2 menghasilkan performa terbaik dengan *Test* RMSE 0,006780 dan *Test* Dstat 53,04%. Gambar 8 merangkum panel-panel diagnostik berikut. (1) Panel *actual vs predicted* (zoom 120 hari terakhir) memperlihatkan kurva prediksi (merah putus-putus) mengikuti harga aktual (biru) dengan rapat, termasuk tren penurunan dari kisaran 1,12 menuju 1,04 sepanjang Agustus 2024–Januari 2025, meskipun tampak pola *time-lag* satu langkah pada titik-titik balik harga. (2) Panel *loss curve* menunjukkan *train loss* dan *validation loss* yang menurun tajam pada *epoch* awal lalu melandai dan konvergen setelah sekitar 20 *epoch*, dengan *validation loss* konsisten di bawah *train loss* dan tanpa indikasi *overfitting*. (3) Panel *residual* (selisih aktual – prediksi) memperlihatkan galat yang tersebar acak di sekitar nol pada rentang $\pm 0,02$ tanpa pola sistematis, menandakan prediksi yang relatif tidak bias dan ragam galat yang stabil. (4) Panel *directional statistic* menandai prediksi arah yang benar (hijau) dan salah (merah) terhadap perubahan harga harian, dengan total 410 prediksi benar dari 773 (53,04%). (5) Panel *rolling Dstat* 30-bar menampilkan akurasi arah pada jendela bergerak 30 hari yang berfluktuasi antara 40–65% (batang hijau di atas dan merah di bawah garis acak 50%), dengan rata-rata keseluruhan 53,0%; fluktuasi ini mencerminkan pergantian kondisi pasar antara fase trending (mudah

diprediksi) dan *ranging/choppy* (sulit diprediksi). Secara keseluruhan, seluruh panel menegaskan bahwa konfigurasi C2 stabil, tidak *overfit*, dan secara konsisten melampaui *baseline* acak 50%.

IV. KESIMPULAN

Penelitian ini berhasil membangun dan mengevaluasi delapan konfigurasi model LSTM untuk memprediksi harga penutupan EUR/USD harian menggunakan fitur log-transformasi OHLC. Seluruh konfigurasi mencapai *Test Dstat* di atas 50%, dengan konfigurasi terbaik C2 (64 unit, 1 *layer*, *dropout* = 0,3) menghasilkan *Test RMSE* sebesar 0,006780 dan *Test Dstat* sebesar 53,04%.

Temuan utama penelitian ini mencakup: konfigurasi *single-layer* secara konsisten menghasilkan generalisasi lebih baik dibandingkan konfigurasi dua *layer*, *Huber loss* terbukti efektif menangani distribusi *log return* yang leptokurtik, pencegahan *data leakage* melalui *fitting scaler* eksklusif di *data training* merupakan langkah kritis dan *Dstat* 53,04% memiliki implikasi praktis yang signifikan dalam konteks trading berbasis sinyal arah.

Sebagai arah penelitian ke depan, direkomendasikan integrasi indikator teknikal (RSI, MACD, *Bollinger Bands*) dan data makroekonomi sebagai fitur tambahan. Eksplorasi arsitektur *Bidirectional LSTM*, mekanisme *attention*, serta pendekatan hibrida TCN-LSTM juga berpotensi meningkatkan kemampuan prediksi arah model secara signifikan.

DAFTAR PUSTAKA

- [1] D. C. Yıldırım, I. H. Toroslu, dan U. Fiore, "Forecasting directional movement of *Forex* data using LSTM with technical and macroeconomic indicators," *Financial Innovation*, vol. 7, no. 1, Des 2021, doi: 10.1186/s40854-020-00220-2.
- [2] H. Hasyddiqy dan H. Hasdiana, "Analisis Peramalan (Forecasting) Penjualan Dengan Metode ARIMA (Autoregressive Integrated Moving Average) Pada Huebee Indonesia," *Data Sciences Indonesia (DSI)*, vol. 2, no. 2, hlm. 92–100, Jan 2023, doi: 10.47709/dsi.v2i2.2022.
- [3] R. Kumar Ray dkk., "MULTI-MARKET FINANCIAL CRISIS PREDICTION: A MACHINE LEARNING APPROACH USING STOCK, BOND, AND *FOREX* DATA," *Int. J. Appl. Math. (Sofia)*, vol. 38, no. 8s, 2025, doi: 10.12732/ijam.v38i8s.602.
- [4] O. S. Adesina dan L. O. Obokoh, "A hybrid framework of deep learning and traditional time series models for exchange rate prediction," *Sci. Afr.*, vol. 29, Sep 2025, doi: 10.1016/j.sciaf.2025.e02818.
- [5] M. R. Pahlevi, "Prediksi Harga *Forex* Menggunakan Algoritma Long Short-Term Memory," *JNANALOKA*, hlm. 69–76, Sep 2023, doi: 10.36802/jnanaloka.2022.v3-no2-69-76.
- [6] M. R. Pahlevi, K. Kusriani, dan T. Hidayat, "Comparison of LSTM and GRU Models for *Forex* Prediction," *sinkron*, vol. 8, no. 4, hlm. 2254–2263, Okt 2023, doi: 10.33395/sinkron.v8i4.12709.
- [7] N. Nengah dkk., "JSIKTI: Jurnal Sistem Informasi dan Komputer terapan Indonesia Deep Learning Approach for USD to IDR Forecasting with LSTM," *JSIKTI: Jurnal Sistem Informasi dan Komputer Terapan Indonesia*, vol. 8, no. 1, hlm. 91–100, 2025, doi: 10.33173/jsikti.210.
- [8] M. Ayitey Junior, P. Appiahene, dan O. Appiah, "*Forex* market forecasting with two-layer stacked Long Short-Term Memory neural network (LSTM) and correlation analysis," *Journal*

- of Electrical Systems and Information Technology, vol. 9, no. 1, Des 2022, doi: 10.1186/s43067-022-00054-1.
- [9] W. Sri Lestari dan M. Ulina, “*Forex* Price Predictions using Hybrid TCN-LSTM and LSTM-TCN Models,” Indonesian Journal of Artificial Intelligence and Data Mining (IJAIDM), vol. 8, no. 3, hlm. 697–705, 2025, doi: 10.24014/ijaidm.v8i3.38354.
- [10] S. Ghahremani dan U. T. Nguyen, “Prediction of foreign currency exchange rates using an attention-based long short-term memory network,” Machine Learning with Applications, vol. 20, hlm. 100648, Jun 2025, doi: 10.1016/j.mlwa.2025.100648.
- [11] W. C. Utomo, “Jurnal Teknologi dan Manajemen Informatika Prediksi Pergerakan Saham BBRI ditengah Issue Ancaman Resesi 2023 dengan Pendekatan Machine Learning,” vol. 9, no. 1, hlm. 20–27, 2023, doi: 10.26905/jtmi.v9i1.9135.
- [12] A. Saghafi, M. Bagherian, dan F. Shokoohi, “Forecasting *Forex* EUR/USD Closing Prices Using a Dual-Input Deep Learning Model with Technical and Fundamental Indicators,” Mathematics, vol. 13, no. 9, Mei 2025, doi: 10.3390/math13091472.
- [13] D. J. Kim, D. H. Kim, dan S. Y. Choi, “Modeling Stylized Facts in FX Markets with FINGAN-BiLSTM: A Deep Learning Approach to Financial Time Series,” Entropy, vol. 27, no. 6, Jun 2025, doi: 10.3390/e27060635.