

Predicting Indonesian Inflation Rate Using Long Short-Term Memory (LSTM)

Muhammad Hafid Krisna Wahyu Wijaya^{1*}, Faulinda Ely Nastiti², Anisatul Farida³

¹ Teknik Informatika, Fakultas Ilmu Komputer, Universitas Duta Bangsa, Surakarta, 57154, Indonesia

^{2,3} Sistem Informasi, Fakultas Ilmu Komputer, Universitas Duta Bangsa, Surakarta, 57154, Indonesia

Informasi Artikel

Diterima : 17 Juni 2025
Revisi : 21 Juli 2025
Publikasi : 30 September 2025

Kata Kunci:

Prediksi Inflasi
Long Short-Term Memory
LSTM
Deep Learning
Ekonomi Makro

ABSTRAK

Inflasi adalah indikator ekonomi krusial yang memerlukan model prediksi akurat. Penelitian ini bertujuan mengembangkan sistem prediksi inflasi bulanan di Indonesia menggunakan arsitektur Long Short-Term Memory (LSTM). Metode meliputi akuisisi data historis dari Bank Indonesia, pra-pemrosesan dengan normalisasi Min-Max Scaler, dan pelatihan model LSTM univariat. Hasil evaluasi menunjukkan performa sangat baik dengan nilai MAE 0.2999, RMSE 0.3903, dan R^2 0.8796, yang mengindikasikan model mampu menjelaskan 88% variabilitas data. Secara khusus, kontribusi penelitian ini adalah implementasi model LSTM univariat yang hanya mengandalkan satu jenis data historis, sehingga menghasilkan baseline prediksi yang transparan, efisien, dan mudah direplikasi. Disimpulkan bahwa LSTM efektif untuk prediksi inflasi di Indonesia dan menjadi landasan yang solid untuk penelitian selanjutnya.

ABSTRACT

Inflation is a crucial economic indicator that requires an accurate prediction model. This research aims to develop a monthly inflation prediction system in Indonesia using the Long Short-Term Memory (LSTM) architecture. The methods include the acquisition of historical data from Bank Indonesia, preprocessing with Min-Max Scaler normalization, and the training of a univariate LSTM model. Evaluation results show excellent performance with an MAE of 0.2999, an RMSE of 0.3903, and an R^2 of 0.8796, indicating that the model can explain 88% of the data's variability. Specifically, the contribution of this research is the implementation of a univariate LSTM model that relies solely on a single type of historical data, thereby producing a transparent, efficient, and easily replicable prediction baseline. It is concluded that LSTM is effective for inflation forecasting in Indonesia and serves as a solid foundation for future research.

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



*Penulis Koresponden

Email: krisnawahyuwijaya456@gmail.com

Cara sitasi IEEE:

M. H. K. W. Wijaya, F. E. Nastiti, & A. Farida, "Predicting Indonesian Inflation Rate Using Long Short-Term Memory (LSTM)," *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 5, no. 3, pp. 1309-1315, September 2025, doi: 10.30811/jaise.v5i3.7178

1. PENDAHULUAN

Indikator makroekonomi yang sangat penting dalam menentukan arah kebijakan sebuah negara adalah inflasi. Perubahan tingkat inflasi berdampak langsung pada kemampuan belanja masyarakat, kestabilan harga,

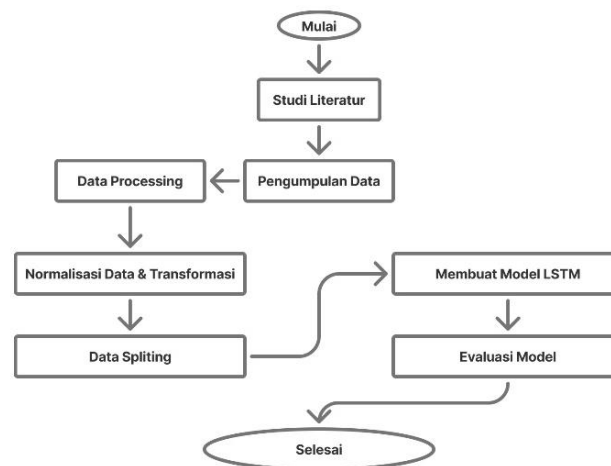
serta pertumbuhan ekonomi secara umum [1]. Maka dari itu, keahlian dalam meramalkan pergerakan inflasi dengan tepat menjadi sangat penting untuk menopang pengambilan keputusan moneter yang berhasil guna dan antisipatif, contohnya dalam menetapkan suku bunga rujukan dan mengontrol peredaran uang. Fenomena ini menjadi perhatian utama dalam disiplin ekonomi makro karena fluktuasi tingkat inflasi yang tidak terkendali dapat merugikan daya beli, memperumit perencanaan keuangan, serta memberikan tekanan ekonomi yang signifikan [2]. Di Indonesia, naik turunnya harga beras sebagai kebutuhan pokok masyarakat dapat berdampak langsung pada tingkat inflasi dan stabilitas ekonomi [3]. Oleh karena itu, kemampuan untuk memprediksi pergerakan inflasi secara akurat menjadi sangat penting untuk merancang kebijakan ekonomi yang responsif dan menjaga kesejahteraan masyarakat. Mengingat karakteristik data inflasi sebagai data deret waktu, diperlukan sebuah metode prediksi yang mampu menangkap pola-pola kompleks dan ketergantungan temporal untuk menghasilkan peramalan yang akurat.

Meramalkan inflasi Indonesia sangatlah sulit. Perubahan harga konsumen bulanan meningkat setiap musim Ramadan–Idul Fitri, diguncang oleh kenaikan harga bahan bakar yang ditetapkan secara administratif, dan dihantam oleh guncangan pangan dan energi global. Kekuatan-kekuatan ini menghasilkan non-linieritas yang nyata dan pemutusan struktural yang melanggar asumsi model deret waktu linier klasik seperti ARIMA atau VAR. Bukti internasional menunjukkan bahwa arsitektur pembelajaran mendalam—terutama jaringan Memori Jangka Pendek Panjang (LSTM)—menangani non-linieritas tersebut jauh lebih baik daripada metode tradisional: dalam eksperimen lintas negara yang besar, LSTM menurunkan kesalahan perkiraan sebesar 84–87 persen relatif terhadap ARIMA. Di Indonesia, studi perbandingan telah mulai mengonfirmasi keunggulan LSTM, tetapi karya yang dipublikasikan hingga saat ini menanamkan jaringan dalam pengaturan multivariat yang kompleks atau menggunakan jendela evaluasi yang pendek [4]. Akibatnya, praktisi masih kekurangan dasar yang transparan dan dapat direproduksi yang berfokus pada satu variabel yang sebenarnya menjadi target BI—inflasi harga konsumen utama [5].

Oleh karena itu, kebaruan utama dari penelitian ini terletak pada pengembangan model LSTM univariat yang secara fundamental berfokus pada kesederhanaan dan efisiensi. Dengan melatih model secara eksklusif pada satu seri data historis inflasi dari Bank Indonesia [6], penelitian ini secara sengaja menghindari kompleksitas yang diperkenalkan oleh variabel-variabel eksogen. Kontribusi uniknya adalah menyediakan sebuah model dasar yang transparan, yang kinerjanya murni mencerminkan kemampuan arsitektur LSTM dalam menangkap pola intrinsik data inflasi Indonesia. [6].

2. METODE

Penelitian ini menggunakan pendekatan kuantitatif Deep Learning yang terdiri dari 5 tahapan yaitu:



Gambar 1 Pipeline Tahapan Penelitian

2.1. Pengumpulan Data

Langkah awal dalam penelitian ini adalah akuisisi data. Data yang digunakan adalah data sekunder berupa data historis inflasi bulanan di Indonesia yang bersumber dari publikasi resmi Bank Indonesia pada web resminya yaitu <https://www.bi.go.id/id/statistik/indikator/data-inflasi.aspx>. Data ini mencakup variabel periode (bulan dan tahun) dan nilai inflasi bulanan dalam rentang waktu 2010 - 2025. Untuk penelitian ini, data inflasi diurutkan berdasarkan periode digunakan sebagai dasar pembentukan model.

2.2. Normalisasi dan Transformasi Data

Tahap transformasi data bertujuan untuk mengubah data mentah ke dalam format yang lebih sesuai untuk diproses oleh algoritma pembelajaran mesin. Normalisasi Data: Data inflasi memiliki rentang nilai yang bervariasi. Untuk menyeragamkan rentang tersebut dan membantu proses konvergensi model saat pelatihan, dilakukan normalisasi data menggunakan metode *Min-Max Scaler*. Metode ini mentransformasi nilai-nilai fitur ke dalam rentang [0, 1]. Proses normalisasi dilakukan menggunakan *library* Scikit-learn pada Python. Persamaan untuk *Min-Max Scaler* adalah sebagai berikut:

$$X_{\text{scaled}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \quad (1)$$

Dimana X adalah nilai data asli, Xmin adalah nilai minimum dalam data, dan Xmax adalah nilai maksimum dalam data. Pembentukan Sekuens Data: Model LSTM memerlukan input berupa sekuens data. Dalam penelitian ini, data deret waktu inflasi yang telah dinormalisasi diubah menjadi format sekuens menggunakan teknik *sliding window*, timesteps = 6 model akan menggunakan 6 data inflasi dari bulan-bulan sebelumnya (t-6, t-5, ..., t-1) untuk memprediksi nilai inflasi pada bulan berikutnya (t). Setiap sekuens input (x_sequences) terdiri dari 6 nilai inflasi historis, dan targetnya (y_sequences) adalah nilai inflasi pada langkah waktu berikutnya.

2.3. Pembagian Data

Setelah data diubah menjadi format sekuens, data tersebut dibagi menjadi dua set: data latih (training data) dan data uji (testing data, praktik standar dan alur yang ditunjukkan pada Diagram Alir 1 menyiratkan adanya pembagian data (80% data latih dan 20% data uji) untuk evaluasi model yang objektif terhadap data yang belum pernah dilihat sebelumnya. Data latih digunakan untuk melatih parameter-parameter internal model LSTM, sementara data uji digunakan untuk mengukur seberapa baik model dapat melakukan generalisasi.

2.4. Arsitektur Model Long Short-Term Memory (LSTM)

Model prediksi dibangun menggunakan arsitektur jaringan LSTM dengan library TensorFlow dan Keras, arsitektur model yang digunakan adalah sebagai berikut:

1. Lapisan LSTM: Satu lapisan LSTM dengan 80 unit. Lapisan ini berfungsi untuk menangkap pola temporal dan dependensi jangka panjang dalam data sekuens inflasi. Parameter input_shape disesuaikan dengan timesteps (6) dan jumlah fitur input (1, yaitu data inflasi). Parameter return_sequences diatur False karena lapisan LSTM ini adalah satu-satunya lapisan LSTM dan outputnya langsung diteruskan ke lapisan Dense.
2. Lapisan Dense (ReLU): Satu lapisan Dense dengan 25 unit dan fungsi aktivasi ReLU (Rectified Linear Unit). Lapisan ini berfungsi sebagai lapisan tersembunyi yang membantu model mempelajari representasi yang lebih kompleks[7].
3. Lapisan Dense (Output): Satu lapisan Dense dengan 1 unit tanpa fungsi aktivasi (atau aktivasi linear implisit), yang menghasilkan nilai prediksi inflasi secara kontinu[8].

Model dikompilasi menggunakan optimizer 'adam' dan fungsi loss 'mae' (Mean Absolute Error). Proses pelatihan dilakukan selama 100 epochs dengan ukuran batch sebesar 8. Model dan scaler yang telah dilatih kemudian disimpan masing-masing sebagai model_inflasi.keras dan scaler.pkl.

2.5. Evaluasi Model

Evaluasi performa model prediksi dilakukan dengan membandingkan nilai prediksi model dengan nilai aktual pada data uji. Metrik evaluasi yang digunakan untuk mengukur tingkat kesalahan dan ketepatan model

Mean Absolute Error (MAE): Rata-rata dari nilai absolut selisih antara nilai aktual dan nilai prediksi.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (2)$$

Mean Squared Error (MSE): Rata-rata dari kuadrat selisih antara nilai aktual dan nilai prediksi. Metrik ini memberikan bobot lebih besar pada kesalahan yang besar.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

Root Mean Squared Error (RMSE): Akar kuadrat dari MSE. Metrik ini memiliki satuan yang sama dengan variabel target, sehingga lebih mudah diinterpretasikan [9].

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

R-squared (R^2): Koefisien determinasi, yang mengukur seberapa baik variasi dalam data target dapat dijelaskan oleh model. Nilai R^2 berkisar antara 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan kesesuaian model yang lebih baik [10].

3. HASIL DAN PEMBAHASAN

Rincian hasil evaluasi dari model LSTM yang telah dikembangkan untuk prediksi inflasi.

3.1. Konfigurasi Lingkungan Eksperimen dan Detail Implementasi Teknis

Penelitian ini membangun model LSTM menggunakan Python dengan pustaka Pandas untuk preparasi data, Scikit-learn (MinMaxScaler) untuk normalisasi, serta TensorFlow/Keras untuk melatih model. Pelatihan dilakukan menggunakan sekuens data 6 bulan untuk memprediksi bulan ketujuh, dengan parameter kunci: optimizer 'adam', fungsi loss 'mae', 100 epoch, dan batch size 8.

3.2. Dinamika Proses Pelatihan Model LSTM

Tahap pelatihan adalah proses inti dalam machine learning [11]. Pada fase ini, model LSTM mengolah data latih untuk secara gradual mengidentifikasi pola-pola yang tersembunyi dalam riwayat data inflasi [12]. Model ini melakukan penyesuaian bobot internal pada setiap koneksi neuronnya melalui mekanisme backpropagation through time yang diulang sebanyak 100 epoch. Sasaran utama dari proses iteratif tersebut adalah untuk menekan nilai loss function (MAE) serendah mungkin, yang merepresentasikan tingkat kesalahan antara prediksi model dan nilai inflasi sesungguhnya, seluruh sekuens data yang disiapkan digunakan pada fase ini agar model dapat menyerap informasi historis semaksimal mungkin [13].

3.3. Kuantifikasi Performa Model Prediktif

Setelah proses pelatihan dianggap selesai, kemampuan generalisasi model yakni kemampuannya untuk bekerja dengan baik pada data baru yang tidak terlihat selama pelatihan diukur melalui evaluasi pada set data uji. Performa prediktif model LSTM dalam meramalkan tingkat inflasi bulanan secara kuantitatif diringkas dalam Tabel berikut, yang menyajikan berbagai metrik evaluasi standar.

Tabel 1. Hasil Uji Model

Metrik Evaluasi	Nilai	Keterangan
Mean Absolute Error (MAE)	0.2999	Rata-rata kesalahan absolut prediksi.
Mean Squared Error (MSE)	0.1523	Rata-rata kuadrat kesalahan, sensitif terhadap kesalahan besar.
Root Mean Squared Error (RMSE)	0.3903	Akar MSE, dalam satuan yang sama dengan data inflasi.
Koefisien Determinasi (R-squared)	0.8796	Proporsi varians data target yang dijelaskan model.

Interpretasi Mendalam Hasil Evaluasi:

- MAE (0.2999): Nilai MAE sebesar 0.2999 mengartikan bahwa, secara rata-rata, prediksi model meleset sekitar 0.3 poin persentase dari nilai inflasi aktual. Dalam konteks fluktuasi inflasi bulanan, kesalahan rata-rata sebesar ini dapat dianggap cukup kecil, menunjukkan kedekatan prediksi dengan realitas.

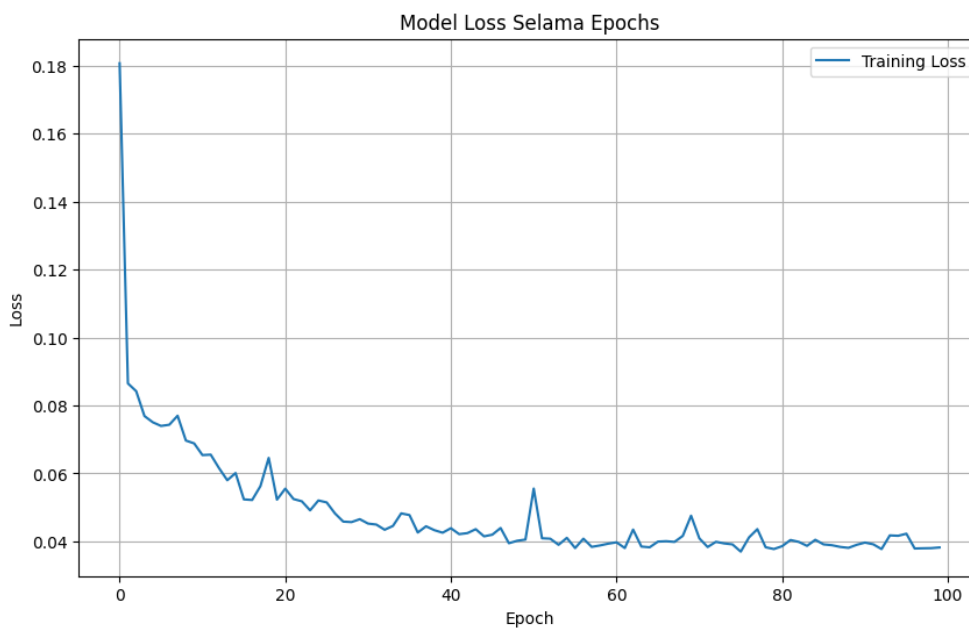
- b) MSE (0.1523) dan RMSE (0.3903): RMSE, yang merupakan akar dari MSE, memberikan ukuran kesalahan yang lebih intuitif karena berada dalam skala yang sama dengan data inflasi [14]. Nilai RMSE 0.3903 mengkonfirmasi temuan dari MAE, dengan sedikit penekanan lebih pada deviasi yang lebih besar karena sifat pengkuadratan pada MSE. Kedua metrik ini secara bersama-sama memberikan gambaran komprehensif mengenai sebaran kesalahan prediksi.
- c) R^2 (0.8796): Koefisien determinasi (R-squared) mencapai 0.8796, atau 87.96%. Angka ini sangat signifikan karena menunjukkan bahwa hampir 88% dari variasi atau pergerakan dalam data inflasi bulanan aktual dapat dijelaskan oleh variabel input historis yang digunakan oleh model LSTM. Ini menandakan tingkat kesesuaian model (goodness of fit) yang tinggi dan kemampuan model untuk menangkap sebagian besar pola yang mendasari data inflasi.

3.4. Analisis Sensitivitas Hyperparameter

Untuk memahami pengaruh berbagai hyperparameter terhadap performa model LSTM, dilakukan serangkaian eksperimen dengan memvariasikan jumlah epoch, ukuran batch size, dan panjang timestep.

Tabel 2. Perbandingan Uji Hyperparameter

Timestep	Epoch	Batch Size	MAE	MSE	RMSE	R^2
6	50	8	0.373	0.247	0.4971	0.8048
6	100	8	0.2999	0.1523	0.3903	0.8796
6	200	8	0.30212	0.1507	0.388	0.8809
6	100	16	0.31625	0.1784	0.42239	0.859
6	100	32	0.44070	0.2699	0.5196	0.78679
12	50	8	0.376784	0.2718	0.5214	0.8016
12	100	8	0.34297	0.21308	0.46161	0.8445
12	200	8	0.33167	0.17246	0.41529	0.87418
12	100	16	0.51696	0.3583	0.5986	0.7385
12	100	32	0.4215	0.2740	0.52351	0.8000
18	100	8	0.3939	0.24043	0.4903	0.82472



Gambar 2 Visualisasi Loss selama Epochs

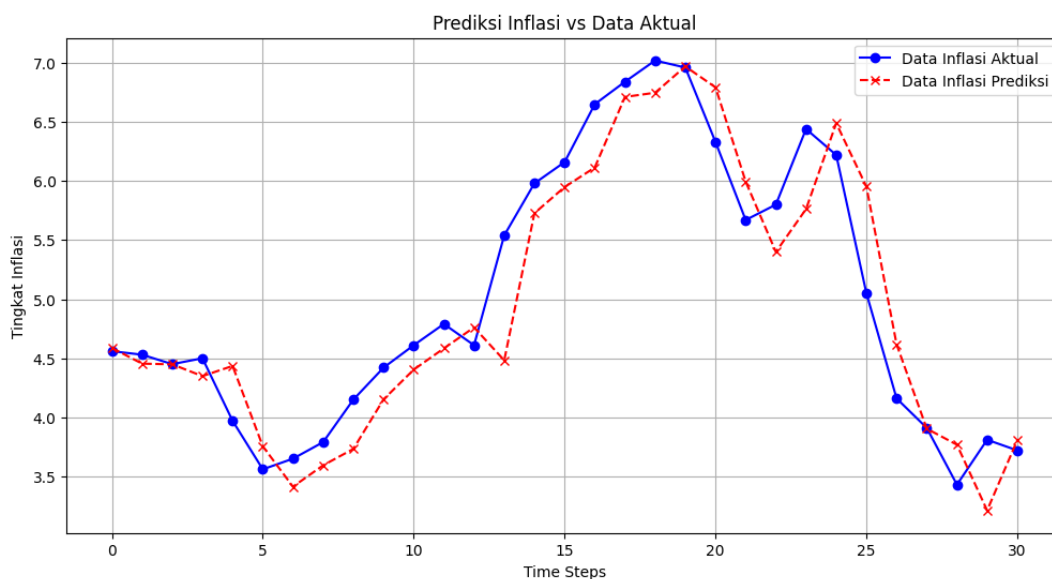
Berdasarkan analisis ini, konfigurasi hyperparameter dengan Timestep 6, Epoch 100 dan Batch Size 8 dipilih sebagai model final karena menunjukkan keseimbangan terbaik antara akurasi prediksi dan potensi overfitting Model prediksi LSTM yang telah dikembangkan kemudian diintegrasikan ke dalam sebuah antarmuka pengguna berbasis web menggunakan Streamlit, memungkinkan pengguna untuk mendapatkan hasil prediksi inflasi secara *real-time*.



Gambar 3 Tampilan Streamlit

3.5. Visualisasi Hasil Prediksi

Untuk memberikan gambaran visual yang lebih jelas mengenai performa model, dilakukan plot perbandingan antara nilai inflasi aktual dengan nilai yang diprediksi oleh model LSTM.



Gambar 4 Visualisasi Data Aktual vs Data Prediksi

3.6. Pembahasan

Hasil evaluasi kuantitatif menunjukkan bahwa model LSTM yang dikembangkan sangat menjanjikan untuk prediksi inflasi bulanan di Indonesia. Pencapaian nilai R^2 sebesar 0.8796 membuktikan kemampuan model dalam mempelajari pola fundamental data inflasi, yang merupakan ciri khas arsitektur LSTM dalam menangani dependensi jangka panjang pada data deret waktu [15]. Meskipun terdapat selisih prediksi yang ditunjukkan oleh nilai MAE (0.2999) dan RMSE (0.3903), tingkat kesalahan ini masih dapat diterima untuk aplikasi praktis sebagai alat analisis awal. Perlu ditekankan bahwa performa ini dicapai hanya dengan menggunakan data historis inflasi (univariat), yang justru menunjukkan kekuatan pemodelan internal LSTM.

Temuan ini konsisten dengan penelitian sebelumnya yang membuktikan efektivitas LSTM untuk prediksi variabel ekonomi lain seperti suku bunga dan nilai tukar. Konfigurasi arsitektur yang relatif sederhana (satu lapisan LSTM dengan 80 unit dan timesteps=6) ternyata sudah mampu memberikan hasil yang sangat kompetitif.

Meskipun kemampuan generalisasi model tergolong baik (dilihat dari R^2), penelitian ini tidak secara eksplisit mengimplementasikan teknik regularisasi seperti dropout untuk menangani overfitting. Hal ini, bersama dengan sifat univariat model, menjadi area utama untuk pengembangan di masa mendatang. Penelitian selanjutnya dapat berfokus pada integrasi variabel ekonomi eksternal, implementasi teknik regularisasi, eksplorasi arsitektur yang lebih kompleks seperti BiLSTM, dan melakukan optimasi hyperparameter secara sistematis untuk meningkatkan akurasi dan robustitas model.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem prediksi inflasi bulanan di Indonesia menggunakan model Long Short-Term Memory (LSTM), sesuai dengan tujuan awal. Model menunjukkan performa yang menjanjikan, dengan nilai R^2 sebesar 0.8796 serta nilai MAE (0.2999) dan RMSE (0.3903) yang dapat diterima, membuktikan bahwa pendekatan univariat LSTM efektif untuk memodelkan data deret waktu inflasi.

Meskipun hasilnya memuaskan, penelitian selanjutnya disarankan untuk mengintegrasikan variabel ekonomi makro eksternal untuk meningkatkan akurasi. Selain itu, implementasi teknik regularisasi seperti Dropout serta eksplorasi arsitektur yang lebih kompleks seperti Bidirectional LSTM (BiLSTM) dan optimasi hyperparameter yang sistematis dapat menjadi fokus pengembangan berikutnya untuk menghasilkan model yang lebih akurat dan signifikan secara praktis.

UCAPAN TERIMAKASIH

Penulis mengucapkan puji syukur kepada Tuhan Yang Maha Esa atas terselesainya penelitian dan penulisan jurnal ini.

Ucapan terima kasih juga ditujukan kepada Universitas Duta Bangsa Surakarta dengan adanya pelatihan penulisan jurnal serta lab Datascience di Fakultas Ilmu Komputer.

REFERENSI

- [1] A. Rizani, R. A. Norrahman, I. Harsono, A. S. Yahya, dan D. M. Syifa, "Efek Inflasi terhadap Daya Beli Masyarakat pada Tinjauan Ekonomi Makro," *Journal of International Multidisciplinary Research*, vol. 1, no. 2, hlm. 344-358, Des. 2023.
- [2] M. Owen, V. Vincent, R. B. Ambarita, dan E. Indra, "Implementasi Metode Long Short Term Memory Untuk Memprediksi Pergerakan Nilai Harga Emas," *Jurnal TEKINKOM*, vol. 5, no. 1, hlm. 96-104, Jun. 2022. doi:10.37600/tekinkom.v5i1.507.
- [3] A. Devi dan P. Hendikawati, "Prediksi Kurs Rupiah Terhadap Dolar dengan Menggunakan Model Long-Short Term Memory," *PRISMA, Prosiding Seminar Nasional Matematika*, vol. 7, hlm. 882-891, 2024.
- [4] F. F. Savitri, R. F. Siregar, F. Y. Harianto, dan H. Napitupulu, "Forecasting Inflation in Indonesia using Long Short Term Memory," dalam *2021 International Conference on Artificial Intelligence and Big Data Analytics (ICAIBDA)*, 2021. doi: 10.1109/ICAIBDA53487.2021.9689700. A. Devi dan P. Hendikawati, "Prediksi Kurs Rupiah Terhadap Dolar dengan Menggunakan Model Long-Short Term Memory," *PRISMA, Prosiding Seminar Nasional Matematika*, vol. 7, hlm. 882-891, 2024. [8] M. Pressley and C. B. McCormick, *Advanced educational psychology for educators, researchers, and policymakers*. New York, USA: HarperCollins College Publishers, 1995.
- [5] S. S. Namin dan A. S. Namin, "Forecasting Economic and Financial Time Series: ARIMA vs. LSTM," 2018.
- [6] Bank Indonesia, "Data Inflasi," Bank Indonesia, diakses tanggal 12 Juni 2025. [Online]. Tersedia: <https://www.bi.go.id/id/statistik/indikator/data-inflasi.aspx>
- [7] S. Sakib, Z. Ashrafi, and M. A. B. Siddique, "Implementation of Fruits Recognition Classifier using Convolutional Neural Network Algorithm for Observation of Accuracies for Various Hidden Layers," *ArXiv e-Journal*, 2019.
- [8] J. P. A. Echevarria and F. F. Balahadia, "Forecasting the Consumer Price Index in the Regions of the Philippines using Machine Learning for Time Series Models," in *Proc. 6th Int. Conf. Inf. Comput. Technol. (ICICT)*, Rizal, Philippines, Mar. 2023, pp. 165-172.
- [9] L. N. Mintarya, J. N. M. Halim, C. Angie, S. Achmad, and A. Kurniawan, "Machine learning approaches in stock market prediction: A systematic literature review," *Procedia Computer Science*, vol. 216, pp. 96-102, 2023.
- [10] L. Sasabone, E. Sudarmanto, Yovita, and S. Adiwijaya, "Pengaruh E-commerce dan Kemudahan Transaksi Terhadap Perubahan Pola Konsumsi Dalam Era Digital Di Indonesia," *Sanskara Ilmu Sosial dan Humaniora*, vol. 1, no. 01, pp. 32-42, Dec. 2023.
- [11] A. Y. Isnaeni and S. Y. J. Prasetyo, "Klasifikasi Wilayah Potensi Risiko Kerusakan Lahan Akibat Bencana Tsunami Menggunakan Machine Learning," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 1, Apr. 2022.
- [12] S. Siami-Namini, N. Tavakoli, and A. S. Namin, "A Comparison of ARIMA and LSTM in Forecasting Time Series," in *Proc. 17th IEEE Int. Conf. Mach. Learn. Appl. (ICMLA)*, Orlando, FL, USA, Dec. 2018, pp. 951-958.
- [13] M. A. F. Geron, A. A. A. Agdan, and J. C. T. Ballesteros, "Short-term Wind Speed Forecasting using Bidirectional Long Short-Term Memory," in *Proc. IEEE 12th Int. Conf. Humanoid Nanotechnol. Inf. Technol. Commun. Environ. Manage. (HNICEM)*, Manila, Philippines, Nov. 2021, pp. 1-6.
- [14] S. M. Agustina and D. Gustian, "Analisis Kinerja Algoritma Prediksi Saham pada PT GoTo Gojek Tokopedia Tbk (GOTO)," *Jurnal Rekayasa Teknologi Nusa Putra*, vol. 11, no. 1, pp. 53-67, Feb. 2025.
- [15] D. M. Nugraha and D. Ariatmanto, "Meningkatkan Akurasi Prediksi Harga Bitcoin dengan Algoritma GRU-LSTM Hibrida," *JURNAL BUFFER INFORMATIKA*, vol. 11, no. 1, Apr. 2025.