

PENERAPAN MODEL LSTM (LONG SHORT-TERM MEMORY) DALAM PERAMALAN INFLASI MONTH ON MONTH DI INDONESIA

Nurul Hadi, Syariful Alam, Imay Kurniawan

Teknik Informatika, Sekolah Tinggi Teknologi Wastukencana Purwakarta
Jl.Cikopak No.53, Kec Purwakarta, Purwakarta, Jawa Barat, Indonesia-41151
Nurulhadi09@wastukencana.ac.id

ABSTRAK

Inflasi sebagai indikator makroekonomi kritis di Indonesia seringkali menunjukkan fluktuasi yang sulit diprediksi menggunakan metode statistik konvensional karena sifatnya yang *non-linier* dan kompleks. Permasalahan utama terletak pada ketidakmampuan model tradisional dalam menangkap pola temporal jangka panjang dan ketergantungan antar-waktu dalam data inflasi, yang berakibat pada ketidakakuratan prediksi. Selain itu, minimnya implementasi teknologi canggih dalam peramalan inflasi menyebabkan keterbatasan alat bantu bagi pembuat kebijakan. Untuk mengatasi masalah ini, penelitian ini mengembangkan model *Long Short-Term Memory* (LSTM) untuk memprediksi inflasi bulanan (*month-on-month*) dengan akurasi tinggi. Menggunakan data Bank Indonesia periode Januari 2003-Mei 2025 (269 observasi), model dibangun melalui pendekatan CRISP-DM dengan normalisasi *MinMaxScaler*, pembentukan *sequence* (15 *time-steps*), dan pembagian data (60:40). Hasil evaluasi menunjukkan performa luar biasa: MSE 0.001573, MAE 0.029463, dan R^2 0.96075, mengindikasikan kemampuan prediksi yang stabil dan akurat. Implementasi aplikasi berbasis Streamlit menyediakan antarmuka interaktif untuk visualisasi data historis, evaluasi model, dan prediksi 12 bulan ke depan, memudahkan pengguna dalam analisis kebijakan. Temuan ini membuktikan keunggulan LSTM dalam menangkap pola kompleks inflasi sekaligus memberikan solusi praktis berbasis deep learning untuk peramalan ekonomi.

Kata kunci: Inflasi, prediksi, LSTM, deep learning, CRISP-DM, Streamlit

1. PENDAHULUAN

Inflasi merupakan indikator makroekonomi kritis yang memengaruhi stabilitas ekonomi Indonesia secara mendalam. Tingkat inflasi yang tinggi atau tidak terkendali dapat menurunkan daya beli masyarakat, menciptakan ketidakstabilan harga, dan mengganggu pertumbuhan ekonomi[1]. Data BPS menunjukkan bahwa lonjakan inflasi di luar perkiraan telah mengurangi daya beli masyarakat berpenghasilan tetap hingga 5,2% pada 2023, sementara sektor UMKM mengalami kerugian mencapai Rp12 triliun akibat ketidakpastian harga bahan baku[2].

Bank Indonesia menetapkan target inflasi nasional sebesar $2.5 \pm 1\%$ untuk tahun 2025 dan 2026 guna menjaga stabilitas perekonomian[3]. Namun, fluktuasi inflasi bulanan (*month-on-month*) di Indonesia seringkali sulit diprediksi menggunakan metode statistik konvensional seperti ARIMA atau GARCH karena sifatnya yang *non-linier* dan kompleks[4]. Ketidakakuratan prediksi ini berdampak sistemik, termasuk pada ketidakstabilan kebijakan moneter dan pembengkakan anggaran subsidi pemerintah.

Long Short-Term Memory (LSTM), sebagai salah satu varian *Recurrent Neural Network* (RNN), telah terbukti efektif dalam menangani data deret waktu yang kompleks dan *non-linier*[5]. LSTM mampu menyimpan informasi jangka panjang dan menangkap pola musiman serta hubungan temporal dalam data, sehingga cocok untuk peramalan inflasi[6]. Beberapa penelitian sebelumnya, seperti yang dilakukan oleh Mutiara et al.[7], menunjukkan bahwa LSTM menghasilkan prediksi inflasi dengan

akurasi lebih tinggi dibandingkan model ARIMA-GARCH.

Penelitian ini bertujuan untuk menerapkan model LSTM dalam meramalkan inflasi bulanan di Indonesia. Metode CRISP-DM (*Cross-Industry Standard Process for Data Mining*) digunakan sebagai kerangka kerja untuk memastikan proses penelitian sistematis dan terstruktur[8]. Data inflasi bulanan dari Bank Indonesia periode Januari 2003 hingga Mei 2025 digunakan untuk pelatihan dan evaluasi model. Hasil penelitian diharapkan dapat memberikan prediksi yang lebih akurat dan stabil, serta menjadi referensi bagi pembuat kebijakan dalam mengendalikan inflasi.

2. TINJAUAN PUSTAKA

2.1. Inflasi

Inflasi adalah kenaikan harga barang dan jasa secara umum dan terus menerus dalam jangka waktu tertentu. Kenaikan harga dari satu atau dua barang saja tidak dapat disebut inflasi kecuali bila kenaikan itu meluas atau mengakibatkan kenaikan harga pada barang lainnya. Perhitungan inflasi dilakukan oleh Badan Pusat Statistik (BPS) di Indonesia[9].

2.2. Peramalan

Peramalan adalah proses membuat prediksi tentang masa depan berdasarkan data masa lalu dan saat ini, yang sering dilakukan dengan menganalisis pola tren. Contoh umumnya adalah memperkirakan nilai suatu variabel tertentu pada waktu tertentu di masa depan[10].

2.3. Long Short-Term Memory (LSTM)

Long-Short Term Memory (LSTM) merupakan salah satu pengembangan dari arsitektur *Recurrent Neural Network* (RNN) dengan memberi *memory cell* untuk dapat menyimpan informasi dalam waktu yang lama dan dapat mengatasi terjadinya *vanishing gradient* pada RNN saat melakukan proses data sekuensial yang Panjang[11].

2.4. Recurrent Neural Network (RNN)

RNN (*Recurrent Neural Network*) adalah jaringan saraf kompleks yang memproses data secara berurutan dengan menyimpan *output* sebagai memori untuk pemrosesan berikutnya. Keunggulan utamanya adalah kemampuan menangkap informasi sekuensial, namun memiliki kelemahan berupa masalah *vanishing/exploding gradients* dan kesulitan memproses rangkaian panjang. Proses pelatihan RNN juga lebih rumit dibanding ANN atau CNN karena kompleksitas arsitekturnya[12].

2.5. MSE

Mean Squared Error (MSE) adalah metrik evaluasi yang umum digunakan dalam statistik dan *machine learning* untuk mengukur seberapa akurat sebuah model regresi dalam memprediksi nilai numerik. MSE mengukur rata-rata kuadrat selisih antara nilai prediksi model dengan nilai sebenarnya dari data yang diamati[13].

$$MSE = \frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2$$

di mana N adalah jumlah sampel data, y_n adalah nilai sebenarnya dari data ke-n, dan $\hat{y}_n$ adalah nilai prediksi dari model untuk data ke-n.

2.6. MAE

Mean Absolute Error adalah ukuran kerugian regresi yang melihat perbedaan nilai absolut antara prediksi model dan kebenaran dasar, yang dirata-ratakan di seluruh kumpulan data. Tidak seperti MSE, MAE dibobot pada skala linier dan karenanya tidak terlalu membebani *outlier*. Ini memberikan ukuran kinerja yang lebih merata, tetapi berarti kesalahan besar dan kesalahan kecil dibobot sama. Sesuatu yang perlu dipertimbangkan tergantung pada kasus penggunaan model spesifik Anda. *Mean Absolute Error* (MAE) adalah metrik yang umum digunakan untuk mengevaluasi keakuratan prediksi. *Mean Absolute Error* (MAE) mengukur rata-rata perbedaan absolut antara nilai aktual dan nilai prediksi. *Mean Absolute Error* (MAE) digunakan ketika tujuannya adalah untuk mengevaluasi kualitas prediksi dalam hal besaran absolutnya, bukan besaran relatifnya[14].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

n = Jumlah Sampel

y_i = Data Aktual

$\hat{y}_i$ = Data Peramalan

2.7. R^2

R-Kuadrat (R^2 atau koefisien determinasi) adalah ukuran statistik dalam model regresi yang menentukan proporsi varians dalam variabel dependen yang dapat dijelaskan oleh variabel independen. Dengan kata lain, r-kuadrat menunjukkan seberapa baik data sesuai dengan model regresi (kebaikan kesesuaian)[15].

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}}$$

Dimana:

SS_{res} = jumlah kuadrat residual (selisih antara nilai aktual dan prediksi)


$$SS_{res} = \sum (y_i - \hat{y}_i)^2$$

SS_{tot} = jumlah kuadrat total (selisih antara nilai aktual dan rata-rata aktual)

$$SS_{tot} = \sum (y_i - \bar{y})^2$$

3. METODE PENELITIAN

CRISP-DM merupakan singkatan dari *Cross-Industry Standard Process for Data Mining* dan mempunyai enam tahapan yaitu *Business understanding*, *Data understanding*, *Data preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Melakukan penelitian dengan metodologi CRISP-DM akan mengikuti tahapan dari 6 fase di atas, dimana masing-masing fase tersebut saling terkait pada fase berikutnya, namun dalam mainstream ini banyak siklus berulang yang dapat diamati[16].



Gambar 1. Tahapan CRISP-DM

3.1. Business Understanding

Penelitian ini bertujuan memprediksi fluktuasi inflasi bulanan di Indonesia yang sulit diramalkan dengan metode statistik konvensional. Dengan pendekatan *deep learning* menggunakan model LSTM (*Long Short-Term Memory*), diharapkan diperoleh hasil peramalan yang lebih akurat, stabil, serta mampu menangkap pola musiman dan hubungan jangka panjang dalam data inflasi.

3.2. Data Understanding

Tahap ini berfokus pada eksplorasi data inflasi bulanan Indonesia (*month-on-month*) dari Januari 2003 hingga Mei 2025 (269 entri), bersumber dari

Bank Indonesia. Data menunjukkan variasi inflasi, seperti 8,68% (Januari 2003) dan 1,60% (Mei 2025). Eksplorasi dilakukan untuk memastikan kesesuaian format, kualitas data, serta menghindari bias atau kesalahan teknis sebelum pemodelan.

3.3. Data Preparation

Pada tahap ini, data dinormalisasi menggunakan *MinMaxScaler* (rentang 0-1) untuk mempercepat pelatihan dan meningkatkan stabilitas model. Data kemudian diubah ke dalam bentuk *sequence* dengan *sliding window*, menggunakan 15 *time -steps* sebelumnya untuk memprediksi nilai ke-16. Selanjutnya, data dibagi menjadi 60% untuk pelatihan dan 40% untuk pengujian guna mengevaluasi kemampuan generalisasi model terhadap data baru.

3.4. Modeling

Proses pemodelan menggunakan arsitektur LSTM, sebuah varian RNN yang unggul dalam pemrosesan data deret waktu. Model ini mampu menangkap dependensi jangka panjang dan pola kompleks dalam data inflasi. Implementasi meliputi: (1) lapisan LSTM untuk ekstraksi fitur temporal, (2) *dropout layer* untuk regularisasi, dan (3) *dense layer* sebagai *output*. Pelatihan dilakukan dengan *optimizer* Adam (1000 *epoch*) dan pengukuran fungsi *error* menggunakan *Loss Mean Squared Error*.

3.5. Evaluation

Kinerja model dievaluasi melalui perbandingan prediksi dengan data aktual menggunakan tiga metrik evaluasi: (1) MSE mengukur presisi prediksi melalui kesalahan kuadrat, (2) MAE memberikan estimasi kesalahan absolut, dan (3) R^2 menilai kemampuan model dalam menjelaskan variasi data. Pendekatan multi-metrik ini memastikan penilaian yang komprehensif terhadap akurasi dan generalisasi model.

3.6. Deployment

Penelitian ini mengimplementasikan model prediksi inflasi ke dalam sistem berbasis web menggunakan *Streamlit*, yang menyediakan antarmuka interaktif bagi pengguna untuk memasukkan parameter prediksi, menampilkan visualisasi komparatif antara data aktual dan hasil prediksi, serta menyajikan *dashboard* evaluasi metrik kinerja model. Implementasi ini dirancang untuk meningkatkan aksesibilitas bagi pengguna non-teknis, transparansi melalui representasi visual yang intuitif, serta utilitas praktis dalam pengambilan keputusan terkait inflasi.

4. HASIL DAN PEMBAHASAN

4.1. Data Understanding

Penelitian ini menggunakan data inflasi bulanan (*month-on-month*) Indonesia yang diperoleh dari Bank Indonesia, dengan rentang periode Januari 2003 hingga Mei 2025 (total 269 observasi). Data diunduh

dalam format Excel dan melalui tahap validasi untuk memastikan kelengkapan dan akurasi. Dapat dilihat pada Tabel 1, lima baris awal data menunjukkan variasi nilai inflasi, termasuk contoh pada Mei 2025 sebesar 1,60% (*month-on-month*).

Tabel 1. Data awal

Periode	Inflasi
2025-05-01	0.0160
2025-04-01	0.0195
2025-03-01	0.0103
2025-02-01	-0.0009
2025-01-01	0.0076

4.2. Data Preparation

Proses ini dilakukan melalui beberapa tahapan kritis untuk memastikan kesiapan data sebelum pemodelan. Pertama, data inflasi dinormalisasi ke dalam rentang 0 hingga 1 menggunakan *MinMaxScaler* dari *library scikit-learn* untuk meningkatkan stabilitas pelatihan model. Hasil normalisasi dapat dilihat pada Tabel 2 yang menunjukkan transformasi nilai inflasi ke dalam skala baru.

Tabel 2. Hasil normalisasi data

Indeks	Nilai Normalisasi
0	0.091500
1	0.110449
2	0.060639
3	0.000000
4	0.046021

Selanjutnya, data yang telah dinormalisasi diubah menjadi bentuk *sequence* menggunakan pendekatan *sliding window* dengan panjang 15-*time steps* untuk memprediksi nilai ke-16. Data kemudian *direshape* menjadi bentuk tiga dimensi (*samples, time steps, features*) yang sesuai dengan kebutuhan *input* model LSTM. Dari total 269 data *point*, dihasilkan 254 *sequence* data.

Proses terakhir adalah pembagian *dataset* menjadi data latih (60%) dan data uji (40%) untuk memvalidasi performa model. Pembagian ini dilakukan dengan mempertahankan urutan temporal data untuk memastikan validasi yang realistis terhadap pola *time series*.

4.3. Modeling

Penelitian ini mengimplementasikan model *Long Short-Term Memory* (LSTM) untuk memprediksi inflasi bulanan di Indonesia. Pemilihan arsitektur LSTM didasarkan pada kemampuannya yang unggul dalam menangkap pola kompleks dan ketergantungan jangka panjang dalam data deret waktu, sekaligus mengatasi masalah *vanishing gradient* yang sering terjadi pada jaringan saraf tradisional.

Model dibangun dengan lapisan LSTM yang terdiri dari:

- units*=20: jumlah sel memori (*neuron*) dalam LSTM.

- b. *seq_len*: panjang urutan *timestep* (15).
- c. 1: jumlah fitur per *timestep*.
- d. *Activation='sigmoid'*: fungsi aktivasi di dalam sel.
- e. *Dropout* sebanyak 20% unit dinonaktifkan saat *training*, agar model tidak *overfitting*.
- f. *Layer Dense* untuk mengeluarkan 1 nilai prediksi.
- g. Fungsi aktivasi sigmoid akan membuat hasil prediksi berada di rentang 0 hingga 1.

Proses kompilasi model menggunakan *optimizer* Adam dengan *learning rate* 0.05 dan fungsi *loss* *Mean Squared Error* (MSE). Pemilihan parameter ini didasarkan pada pertimbangan kecepatan konvergensi dan stabilitas pelatihan. Model kemudian dilatih selama 1000 *epoch* dengan batch size 16, memberikan cukup iterasi bagi model untuk mempelajari pola data secara mendalam.

Tabel 3. Perkembangan nilai loss selama pelatihan model

Epoch	Loss	Epoch	Loss
1	0.0464	8	0.0083
2	0.0317	9	0.0061
3	0.0326	10	0.0076
4	0.0195	11	0.0049
5	0.0119		
6	0.0100	999	0.0018
7	0.0080	1000	0.0015

Hasil pelatihan yang ditunjukkan pada Tabel 3 memperlihatkan perkembangan yang signifikan, dimana nilai *loss* menurun dari 0.0464 pada *epoch* pertama menjadi 0.0015 pada *epoch* ke-1000. Penurunan yang konsisten ini mengindikasikan bahwa model berhasil menangkap pola inflasi dengan baik. Terlihat bahwa setelah *epoch* ke-6, penurunan *loss* mulai stabil dengan fluktuasi minimal, menunjukkan model telah mencapai konvergensi yang baik. Penggunaan *dropout layer* terbukti efektif dalam mencegah *overfitting*, terlihat dari stabilitas penurunan *loss* tanpa adanya fluktuasi besar.

4.4. Evaluation


Evaluasi performa model LSTM dilakukan dengan membandingkan hasil prediksi terhadap data uji menggunakan tiga metrik utama. Berdasarkan Tabel 4, diperoleh hasil sebagai berikut:

Tabel 4. Hasil evaluasi

Metrik evaluasi	Nilai
<i>Mean Squared Error</i> (MSE)	0.001573
<i>Mean Absolute Error</i> (MAE)	0.029463
R^2	0.960750

Hasil evaluasi menunjukkan performa model LSTM yang sangat baik dalam memprediksi inflasi. Nilai *Mean Squared Error* (MSE) sebesar 0.001573

mengindikasikan bahwa rata-rata kuadrat selisih antara nilai prediksi dan aktual berada pada tingkat yang sangat rendah. Demikian pula dengan *Mean Absolute Error* (MAE) sebesar 0.029463 yang menunjukkan tingkat kesalahan absolut prediksi yang minimal. Koefisien determinasi (R^2) sebesar 0.96075 yang mendekati 1 membuktikan bahwa model mampu menjelaskan 96.075% variasi dalam data uji, mengkonfirmasi kemampuan prediktif yang sangat baik.



Gambar 2. Grafik prediksi

4.5. Deployment

Model LSTM yang telah dikembangkan selanjutnya diimplementasikan dalam aplikasi web interaktif menggunakan Streamlit. Aplikasi ini dirancang dengan antarmuka yang *user-friendly* untuk memudahkan pengguna dalam menganalisis inflasi Indonesia. Fitur utama yang disediakan meliputi:


4.6. Visualisasi Data Historis



Gambar 3. Visualisasi data inflasi asli

Aplikasi menyajikan visualisasi komprehensif data inflasi bulanan Indonesia dalam rentang tahun 2004 hingga 2025. Data ditampilkan dalam bentuk grafik interaktif dengan nilai ternormalisasi (skala 0-1) yang memudahkan identifikasi pola dan tren inflasi jangka panjang. Visualisasi ini membantu pengguna memahami konteks historis sebelum melakukan analisis prediktif.

4.7. Evaluasi Model



Gambar 4. Evaluasi model

Bagian evaluasi menampilkan tiga metrik kunci performa model secara jelas: MSE (0.001573), MAE (0.029463), dan R^2 (0.96075). Grafik komparatif prediksi vs aktual menunjukkan tingkat akurasi model dalam mengikuti fluktuasi inflasi, dengan garis prediksi yang hampir sempurna mengikuti pola data riil. Fitur ini memberikan transparansi dan membangun kepercayaan pengguna terhadap hasil prediksi.

4.8. Fitur Prediksi

Bulan	Prediksi_Inflasi (%)
0 2025-06	0.0806
1 2025-07	0.0758
2 2025-08	0.073
3 2025-09	0.0698
4 2025-10	0.0671
5 2025-11	0.0645
6 2025-12	0.0621
7 2026-01	0.06
8 2026-02	0.0581
9 2026-03	0.0564

Gambar 5. Fitur prediksi interaktif

Aplikasi menyediakan panel prediksi interaktif dimana pengguna dapat menentukan periode prediksi (1-12 bulan) melalui input sederhana. Hasil prediksi ditampilkan dalam dua format: tabel numerik bulanan-per-bulan dan visualisasi grafik yang menunjukkan tren inflasi kedepan. Implementasi real-time ini memungkinkan pengguna melakukan berbagai skenario analisis dengan respon langsung dari sistem.

Aplikasi ini tidak hanya berguna bagi analisis ekonomi tetapi juga dapat diakses oleh masyarakat umum melalui perangkat *mobile* dengan memindai QR Code yang disediakan. Implementasi ini membuktikan bahwa model prediksi inflasi berbasis LSTM tidak hanya akurat secara teoritis tetapi juga aplikatif dalam skala praktis.



scan aplikasi disini

Gambar 6. QR-code

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil membuktikan efektivitas model LSTM dalam memprediksi inflasi bulanan Indonesia dengan tingkat akurasi tinggi, ditunjukkan oleh nilai MSE (0.001573), MAE (0.029463), dan R^2 (0.960750) yang optimal. Implementasi model ke dalam aplikasi berbasis *web* menggunakan Streamlit memungkinkan prediksi inflasi secara interaktif dan *real-time*, memudahkan pengguna dalam analisis kebijakan atau perencanaan ekonomi. Untuk pengembangan selanjutnya, disarankan mengeksplorasi varian LSTM seperti *bidirectional* atau model *hybrid* untuk meningkatkan akurasi, mengintegrasikan variabel makroekonomi tambahan seperti nilai tukar atau harga komoditas, melakukan validasi berkala dengan data terbaru untuk memastikan ketahanan model terhadap perubahan ekonomi, serta menyempurnakan aplikasi dengan fitur unggahan data dinamis, fleksibilitas periode prediksi, dan sistem peringatan dini untuk tren inflasi ekstrem.

DAFTAR PUSTAKA

- [1] A. K. Hidayah and R. E. Putra, "Penerapan Metode Long Short Term Memory untuk Memprediksi Harga Beras di Indonesia," *Journal of Informatics and Computer Science*, vol. 06, 2024.
- [2] Kamar Dagang dan Industri Indonesia, "Dampak Inflasi terhadap Sektor UMKM," Kamar Dagang dan Industri Indonesia. Accessed: Jul. 12, 2025. [Online]. Available: <https://kadin.id/data-dan-statistik/profil-ekonomi-indonesia/>
- [3] Bank Indonesia, "BI-Rate Tetap 5,75%: Mempertahankan Stabilitas, Mendukung Pertumbuhan Ekonomi," Bank Indonesia. Accessed: Apr. 17, 2025. [Online]. Available: https://www.bi.go.id/id/publikasi/ruang-media/news-release/Pages/sp_276325.aspx
- [4] A. Mutiara, N. Fitriyati, P. Studi Matematika, F. Sains dan Teknologi, and U. Islam Negeri Syarif Hidayatullah Jakarta, "ANALISIS LAJU PREDIKSI INFLASI DI INDONESIA: PERBANDINGAN MODEL GARCH/ARCH DENGAN LONG SHORT TERM MEMORY," *Lebesgue: Jurnal Ilmiah Pendidikan*

- Matematika, Matematika dan Statistika*, vol. 4, no. 1, 2023, doi: 10.46306/lb.v4i1.
- [5] S. Zahara and Sugianto, "Peramalan Data Indeks Harga Konsumen Berbasis Time Series Multivariate Menggunakan Deep Learning," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 24–30, Feb. 2021, doi: 10.29207/resti.v5i1.2562.
- [6] A. Hanafiah, Y. Arta, H. O. Nasution, and Y. D. Lestari, "Penerapan Metode Recurrent Neural Network dengan Pendekatan Long Short-Term Memory (LSTM) Untuk Prediksi Harga Saham," *Bulletin of Computer Science Research*, vol. 4, no. 1, pp. 27–33, Dec. 2023, doi: 10.47065/bulletincsr.v4i1.321.
- [7] A. Mutiara, N. Fitriyati, P. Studi Matematika, F. Sains dan Teknologi, and U. Islam Negeri Syarif Hidayatullah Jakarta, "ANALISIS LAJU PREDIKSI INFLASI DI INDONESIA: PERBANDINGAN MODEL GARCH/ARCH DENGAN LONG SHORT TERM MEMORY," *Lebesgue: Jurnal Ilmiah Pendidikan Matematika, Matematika dan Statistika*, vol. 4, no. 1, 2023, doi: 10.46306/lb.v4i1.
- [8] Fadlan Sayyidul Anam, Yudhi Raymond Ramadhan, and Muhammad Rafi Muttaqin, "Klasifikasi Penyakit Pada Daun dan Buah Jambu Menggunakan Convolutional Neural Network," *(JOINTECS) Journal of Information Technology and Computer Science*, vol. 8, no. 1, pp. 115–126, 2023.
- [9] K. Anwar, R. K. Iryanto, R. Harahap, A. Sinuraya, and M. Munizu, "Peramalan Inflasi di Indonesia Pasca Pemilu 2024 dengan Metode Time Series Double Exponential Smoothing," *Jurnal EMT KITA*, vol. 9, no. 1, pp. 144–152, Dec. 2024, doi: 10.35870/emt.v9i1.3503.
- [10] F. A. Mohammad, A. M. Rizki, and A. N. Sihananto, "PERAMALAN TINGKAT INFLASI DI INDONESIA MENGGUNAKAN ARTIFICIAL BEE COLONY DAN XGBOOST," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, Aug. 2024, doi: 10.23960/jitet.v12i3.4827.
- [11] A. Yahyadi and F. Latifah, "ANALISIS SENTIMEN TWITTER TERHADAP KEBIJAKAN PPKM DI TENGAH PANDEMI COVID-19 MENGGUNAKAN MODE LSTM," *Journal of Information System, Applied, Management, Accounting and Research*, vol. 6, no. 2, pp. 464–470, May 2022, doi: 10.52362/jisamar.v6i2.791.
- [12] D. Esterlina Br Jabat, L. Yanti Sipayung, and K. Raih Syahputra Dakhi, "PENERAPAN ALGORITMA RECURRENT NEURAL NETWORKS (RNN) UNTUK KLASIFIKASI ULOS BATAK TOBA," *SNISTIK: Seminar Nasional Inovasi Sains Teknologi Informasi Komputer*, vol. 1, no. Mei, pp. 3025–8715, 2024.
- [13] H. H. Nuha, "Mean Squared Error (MSE) dan Penggunaannya," Apr. 2023. [Online]. Available: <https://ssrn.com/abstract=4420880>
- [14] David Burch, "Mean Absolute Error In Machine Learning: What You Need To Know," Arize. Accessed: Jun. 25, 2025. [Online]. Available: <https://arize.com/blog-course/mean-absolute-error-in-machine-learning-what-you-need-to-know/>
- [15] Sebastian Taylor, "R-Squared," Corporate Finance Institute. Accessed: Jun. 25, 2025. [Online]. Available: <https://corporatefinanceinstitute.com/resources/data-science/r-squared/>
- [16] Eggy Herlambang, Lorio Purnomo, and Carola Basuki, "PENINGKATAN DONASI DENGAN STRATEGI PEMASARAN DIGITAL PEDULISEHAT.ID MENGGUNAKAN FRAMEWORK CRISP-DM," *Jurnal Bisnis Darmajaya*, vol. 10, 2024.