

Implementasi Model *Stacked* LSTM dalam Memprediksi Inflasi di Indonesia Berdasarkan Kurs USD/IDR

Mirechelin Kristanaya¹, Aviolla Terza Damaliana², Shindi Shella May Wara³

^{1,2,3}*Sains Data, Universitas Pembangunan "Veteran" Jawa Timur*

¹22083010032@student.upnjatim.ac.id

²aviolla.terza.sada@upnjatim.ac.id

³Shindi.shella.fasikom@upnjatim.ac.id

Corresponding author email: 22083010032@student.upnjatim.ac.id

ABSTRAK

Abstrak — Inflasi merupakan salah satu indikator utama yang mencerminkan stabilitas ekonomi suatu negara. Di Indonesia, dinamika inflasi sangat dipengaruhi oleh kondisi eksternal, terutama fluktuasi nilai tukar rupiah terhadap dolar Amerika Serikat (USD/IDR). Dalam beberapa tahun terakhir, inflasi Indonesia tercatat sangat rendah, seperti pada September 2024 sebesar 1,84%, menurun menjadi 0,76% pada Januari 2025, dan bahkan mengalami deflasi sebesar -0,09% pada Februari 2025. Kondisi tersebut tidak hanya menunjukkan stabilitas harga, tetapi juga mengindikasikan potensi pelemahan permintaan domestik yang perlu diantisipasi. Oleh karena itu, diperlukan model prediksi yang mampu menangkap hubungan kompleks antara inflasi dan nilai tukar. Penelitian ini bertujuan untuk memprediksi tingkat inflasi di Indonesia berdasarkan pengaruh kurs USD/IDR menggunakan model *Stacked Long Short-Term Memory* (*Stacked* LSTM). Hasil penelitian menunjukkan bahwa model *Stacked* LSTM memiliki performa prediksi yang baik dengan nilai *Root Mean Square Error* (RMSE) sebesar 0,0346 dan *Mean Absolute Error* (MAE) sebesar 0,0238. Temuan ini diharapkan dapat menjadi acuan dalam pengembangan sistem peringatan dini inflasi serta mendukung perumusan kebijakan ekonomi terhadap dinamika nilai tukar.

Keywords : *Stacked* LSTM, Prediksi Inflasi, Kurs USD/IDR, *Deep Learning*, Deret Waktu.

I. PENDAHULUAN


Inflasi merupakan salah satu indikator makroekonomi utama yang mencerminkan stabilitas dan arah pertumbuhan ekonomi suatu negara. Perubahan tingkat inflasi mencerminkan bagaimana keseimbangan antara permintaan total barang dan jasa dengan penawaran. Ketika inflasi berada pada level yang terlalu rendah atau bahkan negatif (deflasi) dapat menandakan melemahnya daya beli masyarakat dan menurunnya aktivitas ekonomi domestik. Keadaan inflasi di Indonesia memperlihatkan deflasi yang terjadi pada Februari 2025 sebesar $-0,09\%$ *year-on-year* setelah tren penurunan inflasi dari $1,84\%$ pada September 2024 dan $0,76\%$ pada Januari 2025 menjadi sinyal perlambatan ekonomi nasional yang perlu diwaspadai [1]. Kondisi ini tidak hanya menunjukkan berkurangnya tekanan harga, tetapi juga mengindikasikan lemahnya permintaan domestik yang dapat memengaruhi target pertumbuhan ekonomi pemerintah. Salah satu faktor eksternal yang berperan besar terhadap dinamika inflasi Indonesia adalah fluktuasi nilai tukar Rupiah terhadap Dolar Amerika Serikat (USD/IDR). Depresiasi Rupiah menyebabkan kenaikan harga barang impor dan mendorong imported inflation, sedangkan apresiasi Rupiah menekan inflasi tetapi dapat memperlemah daya saing ekspor. Pada Agustus 2025, nilai tukar Rupiah sempat mencapai Rp 16.490 per USD, mencerminkan tekanan eksternal akibat kebijakan moneter ketat The Fed dan ketidakpastian global [2]. Oleh karena itu, perlunya prediksi inflasi berdasarkan nilai tukar Rupiah terhadap Dolar Amerika sebagai dasar pengambilan kebijakan stabilitas harga nasional.

Permasalahan utama dalam pemodelan inflasi terletak pada kompleksitas hubungan non-linear antara variabel makroekonomi, khususnya antara inflasi dan kurs. Model statistik tradisional seperti *Autoregressive Integrated Moving Average* (ARIMA) dan *Exponential Smoothing* (ETS) dinilai kurang mampu menangkap pola non-linier serta ketergantungan jangka panjang antar variabel ekonomi [3]. Dalam konteks ini, pendekatan *deep learning*, terutama *Long Short-Term Memory* (LSTM), menjadi alternatif yang menjanjikan karena mampu mempelajari pola sekuensial serta dependensi jangka panjang pada data deret waktu [4]. Penelitian [2] menggunakan LSTM dan *Gated Recurrent Unit* (GRU) untuk peramalan nilai tukar Rupiah terhadap USD dan menunjukkan efektivitas kedua model tersebut dalam mengenali pola jangka panjang nilai tukar. Sementara itu, penelitian [5] membuktikan bahwa pendekatan *Stacked LSTM*, yang merupakan pengembangan dari LSTM dengan lebih dari satu lapisan tersembunyi, mampu meningkatkan akurasi prediksi harga beras di Jawa Timur karena lebih baik dalam mempelajari pola non-linear.

Berdasarkan keterbatasan penelitian sebelumnya, penelitian ini mengusulkan model *Stacked LSTM* untuk memprediksi inflasi di Indonesia dengan kurs USD/IDR sebagai variabel eksogen. Model ini diharapkan mampu menangkap hubungan jangka pendek dan jangka panjang secara bersamaan. Penelitian juga menerapkan optimasi hyperparameter menggunakan *Grid Search* untuk memperoleh konfigurasi terbaik berdasarkan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE). Penelitian ini diharapkan dapat mendukung pengembangan sistem peringatan dini inflasi-deflasi serta memberikan masukan empiris bagi kebijakan moneter dan stabilitas harga nasional.

II. METODOLOGI PENELITIAN

Metodologi penelitian ini menjelaskan tahapan yang dilakukan pada penelitian ini. Proses penelitian mencakup pengumpulan dan pengolahan data, pembangunan model dasar, pencarian kombinasi *hyperparameter* terbaik melalui metode *Grid Search*, serta evaluasi kinerja model. Adapun alur dalam penelitian ini sebagai berikut:



Gambar 1. Alur Penelitian

II.1 DATA

Data yang digunakan dalam penelitian ini merupakan data deret waktu (*time series*) bulanan dari Januari 2000 hingga September 2025. Variabel utama meliputi tingkat inflasi Indonesia sebagai target (variabel dependen) dan nilai tukar USD/IDR sebagai variabel eksogen (variabel independen). Data diperoleh dari Badan Pusat Statistik (BPS) dan Bank Indonesia (BI).

Tabel 1. Dataset

Tahun	Bulan	Inflasi	Kurs USD/IDR
2000	Januari	1,32	Rp. 7.445
2000	Februari	0,07	Rp. 7.435
...	...	...	...
2025	Agustus	-0,08	Rp. 16.490
2025	September	0,21	Rp. 16.358

II.2 PREPROCESSING DATA

Tahapan preprocessing data dilakukan untuk memastikan bahwa data yang digunakan dalam penelitian memiliki kualitas yang baik dan siap untuk dianalisis. Proses ini mencakup beberapa langkah utama, yaitu pembersihan data, penanganan nilai yang hilang atau tidak valid, konversi format waktu, serta penyusunan data berdasarkan urutan waktu. Proses ini sangat penting karena model berbasis memori seperti LSTM sangat sensitif terhadap urutan serta konsistensi data dan memerlukan rangkaian input yang bersih dan terstruktur. [6].

II.3 NORMALISASI DAN PEMBENTUKAN SEQUENCE


Tahap ini bertujuan untuk menyiapkan data agar sesuai dengan kebutuhan arsitektur LSTM yang dirancang. Arsitektur LSTM memerlukan data dalam bentuk tiga dimensi dengan format [jumlah sampel, jumlah *time step*, jumlah fitur]. Oleh karena itu, proses pembentukan *sequence* dilakukan untuk mengonversi data deret waktu satu dimensi menjadi bentuk tiga dimensi yang sesuai dengan input layer LSTM. Proses normalisasi menggunakan metode *Min Max Scaling* untuk menyetarakan rentang nilai antar variabel pada interval [0,1] sehingga proses pelatihan menjadi lebih stabil. Rumus yang digunakan sebagai berikut:

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

Selanjutnya, dilakukan pembentukan *sequence* atau *windowing* untuk menghasilkan pasangan *input output* yang mencerminkan urutan waktu. Tahapan ini akan meningkatkan kinerja model dalam memprediksi data seret waktu jika dilakukan dengan tepat [7].

II.4 MODEL STACKED LSTM

Pada penelitian ini, fungsi `build_stacked_lstm()` digunakan sebagai model dasar (*baseline model*) untuk membangun dan mengevaluasi berbagai kombinasi parameter pada tahap pencarian *hyperparameter*. Model ini dikembangkan menggunakan arsitektur *Sequential* dari pustaka Keras, yang terdiri dari beberapa lapisan LSTM yang disusun secara bertingkat (*stacked*).



Gambar 1 Alur *Baseline Stacked LSTM*

Lapisan pertama LSTM didefinisikan dengan parameter *input_shape* sesuai bentuk data deret waktu yang telah dibentuk, serta menggunakan *return_sequences=True* agar keluaran dari lapisan ini tetap berupa urutan dan dapat diteruskan ke lapisan berikutnya. Jika jumlah lapisan yang digunakan lebih dari dua, maka ditambahkan lapisan LSTM tambahan menggunakan perulangan *for* dengan pengaturan yang sama. Lapisan terakhir LSTM tidak menggunakan *return_sequences*, karena hanya menghasilkan keluaran akhir dari urutan data.

Setelah lapisan LSTM terakhir, ditambahkan lapisan *Dropout(0.2)* sebagai teknik regularisasi untuk mencegah *overfitting* dengan menonaktifkan sebagian neuron secara acak. Selanjutnya, ditambahkan lapisan *Dense(1)* sebagai lapisan keluaran dengan satu neuron output dan fungsi aktivasi linear, yang digunakan untuk menghasilkan nilai prediksi inflasi berdasarkan pola historis kurs USD/IDR. Model juga menggunakan optimizer Adam.

Fungsi `build_stacked_lstm()` ini bersifat fleksibel dan digunakan berulang kali selama proses *Grid Search* untuk menemukan kombinasi parameter terbaik. Dalam penelitian ini, parameter yang diuji meliputi jumlah neuron, jumlah lapisan LSTM, dan nilai

learning rate. Setiap kombinasi diuji melalui pelatihan model menggunakan data latih dan hasilnya dievaluasi berdasarkan nilai *loss* pada data validasi. Setelah kombinasi parameter terbaik (*best parameter*) diperoleh, model *Stacked LSTM* baru akan dibangun kembali menggunakan konfigurasi tersebut sebagai model utama. Model akhir ini kemudian akan dilatih ulang menggunakan seluruh data latih dan dievaluasi performanya terhadap data uji untuk mengukur kemampuan prediksi inflasi di Indonesia berdasarkan kurs USD/IDR.

II.5 HYPERPARAMETER (*Grid Search*)

Tahapan ini bertujuan untuk memperoleh konfigurasi hyperparameter yang optimal pada model *Stacked LSTM* melalui metode *Grid Search*. Pendekatan ini dilakukan dengan menguji berbagai kombinasi parameter untuk menemukan konfigurasi yang menghasilkan kinerja terbaik berdasarkan metrik evaluasi. Kombinasi parameter yang digunakan dalam penelitian ini sebagai berikut:

Tabel 2. Kombinasi Parameter

Parameter	Kombinasi
Pembagian data pelatihan dan pengujian (<i>train ratio</i>)	0.7, 0.8, 0.9
<i>Time step</i>	3 dan 6
Jumlah <i>neuron</i>	32 dan 64
Jumlah <i>layers</i>	2 dan 3
<i>Batch Size</i>	16 dan 32
<i>Learning rate</i>	0.001 dan 0.005

II.6 EVALUASI MODEL

Tahapan evaluasi dilakukan untuk menilai tingkat kinerja model dalam menghasilkan prediksi terhadap data. Evaluasi dilakukan menggunakan dua metrik utama, yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE). *Root Mean Squared Error* (RMSE) mengukur rata-rata kesalahan kuadrat antara hasil prediksi dengan nilai aktual, kemudian diakarkan agar kembali ke satuan data aslinya. Rumus RMSE ditunjukkan pada persamaan (7):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

Mean Absolute Error (MAE) digunakan untuk menghitung rata-rata dari nilai absolut selisih antara hasil prediksi dan nilai aktual. Metrik ini menunjukkan seberapa besar rata-rata kesalahan yang terjadi dalam satuan yang sama dengan data aslinya. Rumus MAE ditunjukkan pada Persamaan (8):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

III. HASIL DAN ANALISIS

III.1 PREPROCESSING DATA

Tahap prapemrosesan diawali dengan menggabungkan kolom “Tahun” dan “Bulan” menjadi kolom “Tanggal” berformat “YYYY-MM-DD” menggunakan fungsi `pd.to_datetime`, kemudian menghapus nilai yang hilang atau tidak valid (seperti tanda “-”) serta mengonversinya menjadi tipe numerik *float*. Selanjutnya, kolom “Tanggal” dijadikan indeks agar data tersusun berdasarkan urutan waktu.

Karena model LSTM sensitif terhadap skala data, seluruh variabel dinormalisasi menggunakan *MinMaxScaler* dari pustaka *scikit-learn* ke dalam rentang 0–1 untuk menjaga konsistensi skala antarvariabel. Setelah normalisasi, data dibentuk menjadi *sequence* deret waktu melalui fungsi `create_dataset()` yang membagi data menjadi pasangan input (X) dan target (y) berdasarkan parameter *time_step*. Berikut tampilan data setelah dinormalisasi:

Tabel 3. Data Setelah dinormalisasi

Inflasi	Kurs USD/IDR
0.219873	0.001091
0.087738	0.219873
0.032770	0.000000
0.139535	0.053464
0.169133	0.132024

III.2 HASIL GRID SEARCH

Pencarian *hyperparameter* dilakukan menggunakan metode *Grid Search* untuk mengeksplorasi kombinasi parameter yang berpengaruh terhadap kinerja model. Total 96 kombinasi diuji meliputi variasi rasio pembagian data (*train ratio*), panjang *time step*, jumlah neuron, jumlah lapisan LSTM, *batch size*, jumlah *epoch*, dan *learning rate*. Evaluasi setiap kombinasi didasarkan pada nilai Root Mean Squared Error (RMSE) pada data validasi atau uji. Didapatkan parameter terbaik berdasarkan RMSE terkecil sebagai berikut:

Tabel 4. Kombinasi Parameter Terbaik

Parameter	Kombinasi
<i>Train ratio</i>	0.7
<i>Time step</i>	3
Jumlah <i>neuron</i>	64
Jumlah <i>layers</i>	2
<i>Batch Size</i>	32
<i>Epoch (Max)</i>	100
<i>Learning rate</i>	0.005

III.3 MODEL STACKED LSTM DENGAN HASIL PARAMETER TERBAIK

Berdasarkan hasil *Grid Search*, model akhir yang digunakan dalam penelitian ini

merupakan arsitektur *Stacked LSTM* dengan konfigurasi terbaik. Model menerima masukan berupa *sequence* berdimensi '*time_step* = 3' dan dua fitur utama (tingkat inflasi dan nilai tukar USD/IDR).

Arsitektur terdiri atas dua lapisan LSTM berturut-turut, masing-masing dengan 64 neuron, di mana lapisan pertama diatur dengan '*return_sequences=True*' dan lapisan kedua dengan '*return_sequences=False*'. Setelahnya ditambahkan lapisan *dropout* sebesar 0,2 untuk mengurangi risiko *overfitting*, serta lapisan *dense* dengan satu neuron untuk menghasilkan nilai prediksi inflasi.

Model menggunakan *optimizer* Adam dengan *learning rate* sebesar 0,005. Proses pelatihan dilakukan dengan *batch size* 32 selama maksimum 100 *epoch*, serta menerapkan mekanisme *EarlyStopping* dengan *patience* 10 untuk menghentikan pelatihan secara otomatis apabila nilai *validation loss* tidak menunjukkan perbaikan selama 10 *epoch* berturut-turut.


III.4 EVALUASI MODEL

Setelah model dengan *hyperparameter* terbaik menggunakan *grid search* telah dibangun maka dilakukan evaluasi performa model untuk menilai prediksi model *Stacked LSTM* terhadap data uji.

Tabel 5. Hasil Evaluasi

RMSE	0.0346
MAE	0.0238

Hasil evaluasi menunjukkan bahwa model *Stacked LSTM* menghasilkan nilai RMSE = 0.0346 dan MAE = 0.0238 pada data uji yang telah dinormalisasi. Kombinasi kedua metrik ini mencerminkan bahwa selisih rata-rata antara prediksi dan observasi relatif kecil pada skala ternormalisasi, dan bahwa distribusi kesalahan tidak didominasi oleh beberapa prediksi ekstrem.



Gambar 2. Perbandingan Nilai Inflasi aktual dan Hasil Prediksi *Stacked LSTM*

Dari Gambar 2, terlihat bahwa garis prediksi (garis putus-putus) mengikuti arah dan tren umum nilai aktual (garis penuh) pada sebagian besar periode uji. Model menunjukkan kecocokan yang baik pada periode dengan fluktuasi moderat.

KESIMPULAN

Pembangunan model *Stacked LSTM* untuk memprediksi tingkat inflasi Indonesia dengan menggunakan variabel eksogen kurs USD/IDR telah berhasil dilakukan menggunakan parameter terbaik, yaitu *train ratio* = 0.7, *time step* = 3, dua lapisan LSTM

masing-masing 64 *neuron*, *batch size* = 32, *epochs* = 100, dan *learning rate* = 0.005. Model terbaik menghasilkan metrik evaluasi sebesar RMSE = 0.0346 dan MAE = 0.0238. Secara interpretatif, nilai RMSE dan MAE yang relatif kecil menunjukkan bahwa model *Stacked LSTM* mampu mengikuti pola trend inflasi secara umum dan memberikan prediksi yang konsisten terhadap data uji.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada semua pihak yang telah mendukung terselesaikannya penelitian ini, khususnya kepada DISCOVER sebagai wadah publikasi, pembimbing yang memberikan arahan dan masukan selama pengerjaan penelitian ini, teman-teman, serta keluarga yang selalu memberikan dukungan moral. Semoga penelitian ini bermanfaat bagi pengembangan ilmu dan praktik kebijakan di bidang ekonomi makro.

REFERENSI

- [1] Badan Pusat Statistik, “Perkembangan Indeks Harga Konsumen Februari 2025,” Jakarta, Mar. 2025. Accessed: Oct. 29, 2025. [Online]. Available: <https://www.bps.go.id/>
- [2] B. Marietta, R. Santoso, and A. A. Sa’adah, “PERAMALAN NILAI TUKAR RUPIAH TERHADAP DOLLAR AMERIKA DENGAN METODE LONG SHORT-TERM MEMORY DAN GATED RECURRENT UNIT,” *Jurnal Gaussian*, vol. 14, no. 1, pp. 13–22, Feb. 2025, doi: 10.14710/j.gauss.14.1.13-22.
- [3] Hermansah, M. Muhajir, and P. Canas Rodrigues, “Indonesian Inflation Forecasting with Recurrent Neural Network Long Short-Term Memory (RNN-LSTM),” no. 2, pp. 132–142, Sep. 2024, [Online]. Available: <https://journal.uui.ac.id/ENTHUSIASTIC>
- [4] Y. Perdana, N. Raisa Hanum, A. Rabiula, and Y. Anzari, “ANALISIS PERBANDINGAN MODEL GRU DAN LSTM UNTUK PREDIKSI HARGA SAHAM BANK RAKYAT INDONESIA,” *Jurnal Akademika*, vol. 17, no. 2, Jun. 2025, doi: <https://doi.org/10.53564/akademika.v17i2.1692>.
- [5] Y. Nur Sukmaningtyas, S. Zahara, and M. Fatchiyatur Rohmah, “PEMODELAN PREDIKSI HARGA BERAS MEDIUM WILAYAH JAWA TIMUR MENGGUNAKAN STACKED LSTM,” vol. 3, no. 2, pp. 20–24, Dec. 2023, Accessed: Oct. 29, 2025. [Online]. Available: <https://doi.org/10.36815/submit.v3i2.3061>
- [6] I. Malashin, V. Tynchenko, A. Gantimurov, V. Nelyub, and A. Borodulin, “Applications of Long Short-Term Memory (LSTM) Networks in Polymeric Sciences: A Review,” *Polymers (Basel)*, Sep. 2024, doi: 10.3390/polym.
- [7] Y. Setiawan and P. Kartikasari, “PREDIKSI HARGA JUAL KAKAO DENGAN METODE LONG SHORT-TERM MEMORY MENGGUNAKAN METODE OPTIMASI ROOT MEAN SQUARE PROPAGATION DAN ADAPTIVE MOMENT ESTIMATION DILENGKAPI GUI RSHINY,” vol. 11, no. 1, pp. 99–107, 2022, [Online]. Available: <https://ejournal3.undip.ac.id/index.php/gaussian/>