

Prediksi Laju Inflasi dengan Metode Long Short-Term Memory (LSTM) Berdasarkan Data Laju Inflasi dan Pengeluaran Kota Ternate

Frangky Aristiadi Masipupu, Adi Setiawan, Bambang Susanto



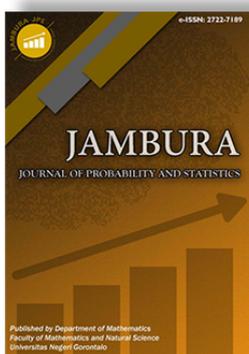
Volume 6, Issue 1, Pages 28–34, May 2025

Received 13 February 2025, Revised 29 April 2025, Accepted 30 Mei 2025, Published Online 31 Mei 2025

To Cite this Article : F.A. Masipupu, A.Setiawan, B. Susanto, “ Prediksi Laju Inflasi dengan Metode Long Short-Term Memory (LSTM) Berdasarkan Data Laju Inflasi dan Pengeluaran Kota Ternate ”, *Jambura J. Probab. Stat.*, vol. 6, no. 1, pp. 28–34, 2025, <https://doi.org/10.34312/jjps.v4i1.30627>

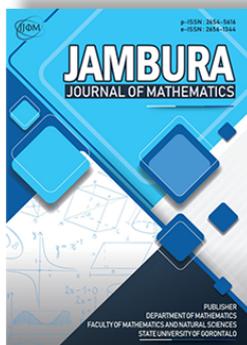
© 2025 by author(s)

JOURNAL INFO • JAMBURA JOURNAL OF PROBABILITY AND STATISTICS



	Homepage	: https://ejournal.ung.ac.id/index.php/jps/index
	Journal Abbreviation	: Jambura J. Probab. Stat.
	Frequency	: Biannual (May and November)
	Publication Language	: English (preferable), Indonesia
	DOI	: https://doi.org/10.34312/jjbm
	Online ISSN	: 2722-7189
	Editor-in-Chief	: Ismail Djakaria
	Publisher	: Department of Mathematics, Universitas Negeri Gorontalo
	Country	: Indonesia
	OAI Address	: http://ejournal.ung.ac.id/index.php/jps/oai
	Google Scholar ID	: kWdujzMAAAJ
	Email	: redaksi.jjps@ung.ac.id

JAMBURA JOURNAL • FIND OUR OTHER JOURNALS



Jambura Journal of Mathematics



Jambura Journal of Mathematics Education



Jambura Journal of Biomathematics



EULER : Jurnal Ilmiah Matematika, Sains, dan Teknologi

Prediksi Laju Inflasi dengan Metode Long Short-Term Memory (LSTM) Berdasarkan Data Laju Inflasi dan Pengeluaran Kota Ternate

Frangky Aristiadi Masipupu¹, Adi Setiawan², Bambang Susanto³

^{1,2,3}Fakultas Sains dan Matematika, Universitas Kristen Satya Wacana

ARTICLE HISTORY

Received 13 February 2025

Revised 29 April 2025

Accepted 30 Mei 2025

Published 31 Mei 2025

KATA KUNCI

Long Short-Term Memory (LSTM),
Inflasi, Pengeluaran, prediksi,
Deret waktu

KEYWORDS

Long Short-Term Memory (LSTM),
Inflation data, Spending,
prediction, Time series.

ABSTRAK. Inflasi merupakan salah satu indikator utama yang mencerminkan kestabilan ekonomi suatu daerah. Kota Ternate, sebagai salah satu kota di Provinsi Maluku Utara, menunjukkan dinamika inflasi yang fluktuatif dari tahun ke tahun. Penelitian ini bertujuan untuk memprediksi laju inflasi di Kota Ternate menggunakan metode Long Short-Term Memory (LSTM), salah satu arsitektur jaringan saraf tiruan yang unggul dalam memproses data deret waktu. Data yang digunakan adalah data Indeks Harga Konsumen (IHK) bulanan Kota Ternate dari tahun 2016 hingga 2023 yang diperoleh dari Badan Pusat Statistik (BPS). Model LSTM kemudian dilatih berdasarkan perubahan IHK bulanan. Hasil evaluasi model menunjukkan nilai Root Mean Square Error (RMSE) sebesar 0.9275, Mean Absolute Error (MAE) sebesar 0.8369, dan Mean Absolute Percentage Error (MAPE) sebesar 20.13%. Nilai-nilai ini mengindikasikan bahwa model LSTM memiliki performa yang baik dalam memprediksi inflasi di Kota Ternate, serta dapat digunakan sebagai alat bantu dalam perencanaan dan pengambilan kebijakan ekonomi daerah.

ABSTRACT. Inflation is one of the main indicators that reflect the economic stability of a region. Ternate City, as one of the cities in North Maluku Province, exhibits fluctuating inflation dynamics from year to year. This study aims to forecast the inflation rate in Ternate using the Long Short-Term Memory (LSTM) method, which is a neural network architecture well-suited for processing time series data. The data used consists of monthly Consumer Price Index (CPI) figures for Ternate from 2016 to 2023, obtained from the Central Bureau of Statistics (BPS). The LSTM model was trained using monthly CPI changes as the basis for calculating inflation. The model evaluation results show a Root Mean Square Error (RMSE) of 0.9275, Mean Absolute Error (MAE) of 0.8369, and Mean Absolute Percentage Error (MAPE) of 20.13%. These results indicate that the LSTM model performs well in forecasting inflation in Ternate City and can be utilized as a decision-support tool in regional economic planning and policymaking.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. *Editorial of JJPS:* Department of Statistics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

1. Pendahuluan

Inflasi merupakan kenaikan harga barang dan jasa dalam jumlah besar yang terjadi secara terus-menerus pada periode tertentu. Salah satu tanda terjadinya inflasi adalah meningkatnya peredaran uang kertas akibat penurunan nilai mata uang, yang berdampak kepada kenaikan harga barang dan jasa [1][2]. Laju inflasi merupakan indikator penting dalam menilai stabilitas ekonomi suatu negara atau wilayah. Kota Ternate sebagai salah satu kota di Indonesia juga mengalami fluktuasi laju inflasi yang dapat dipengaruhi oleh berbagai faktor seperti pengeluaran rumah tangga, belanja pemerintah, dan kenaikan harga komoditas tertentu. Oleh karena itu, prediksi inflasi yang akurat sangat penting untuk membantu pemerintah dan pemangku kepentingan di tingkat kota dalam mengambil keputusan ekonomi yang tepat [3].

Laju inflasi menjadi perhatian utama karena mencerminkan keberhasilan pengelolaan ekonomi dan menjadi dasar dalam pe-

rumusan kebijakan fiskal maupun moneter [4]. Perubahan inflasi juga berpengaruh pada tingkat suku bunga, nilai tukar, dan daya beli masyarakat. Dalam rangka mendukung pengambilan keputusan diperlukan suatu metode peramalan yang mampu menangkap pola perubahan inflasi secara akurat [4]. Salah satu indikator untuk mengukur laju inflasi adalah Indeks Harga Konsumen (IHK) yaitu ukuran rata-rata perubahan harga dari barang dan jasa yang dikonsumsi oleh rumah tangga. Perubahan IHK dari waktu ke waktu mencerminkan laju inflasi [5].

Metode Long Short Term Memory (LSTM) merupakan pengembangan dari metode Recurrent Neural Network (RNN) yang mengatasi kekurangan RNN dalam mengelola informasi jangka panjang [7]. LSTM memiliki kemampuan dalam mempertahankan memori selama periode waktu yang panjang melalui struktur gating yang kompleks [6], sehingga membuat LSTM sangat efektif dalam menangani data deret waktu (time series) [7][8]. LSTM juga terbukti unggul dalam mendeteksi pola musiman dan tren yang tersembunyi dalam data historis, menjadikannya sangat relevan

*Corresponding Author.

untuk tugas peramalan ekonomi, termasuk prediksi laju inflasi [?] [9].

Meskipun telah banyak penelitian yang dilakukan mengenai peramalan inflasi di tingkat nasional atau provinsi, studi yang secara khusus menyoroti prediksi laju inflasi di tingkat kota, terutama di kota Ternate masih sangat terbatas. Selain itu penggunaan metode *deep learning* seperti LSTM dalam konteks lokal ini belum banyak dijelajahi. Oleh karena itu, penelitian ini menawarkan pendekatan baru dengan memanfaatkan model LSTM untuk prediksi laju inflasi tahunan (*year-on-year*) berdasarkan data historis inflasi dan pengeluaran tahunan di kota Ternate. Penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan model prediksi inflasi yang lebih akurat dan kontekstual di tingkat lokal. Hasil dari penelitian ini dapat dimanfaatkan oleh pemerintah, pelaku usaha dan masyarakat dalam merumuskan kebijakan ekonomi yang responsif dan adaptif terhadap dinamika ekonomi di kota Ternate.

2. Metode Penelitian

Data yang digunakan dalam penelitian ini terdiri dari 2 variabel utama, yaitu data pengeluaran pemerintah Kota Ternate (variabel independen) sebagai input dan data laju inflasi Kota Ternate (variabel dependen) sebagai output yang diperoleh dari Badan Pusat Statistik (BPS) Kota Ternate mencakup periode Januari 2018 hingga Mei 2024 disajikan pada [fig. 1](#) dengan 10 baris awal data.

	Bulan	Y on Y	Pengeluaran
1	2018-01	2.00	851809
2	2018-02	2.33	851809
3	2018-03	3.28	851809
4	2018-04	3.54	851809
5	2018-05	3.75	851809
6	2018-06	3.91	851809
7	2018-07	1.88	851809
8	2018-08	3.15	851809
9	2018-09	3.67	851809
10	2018-10	3.26	851809

Figure 1. Inflasi dan Pengeluaran kota Ternate dari tahun 2018 - 2024

Model yang digunakan dalam penelitian ini adalah Long Short-Term Memory (LSTM) merupakan arsitektur jaringan saraf dalam kategori Recurrent Neural Network (RNN). Pendekatan penelitian ini dipergunakan berdasarkan sifat data time-series dan kemampuan LSTM dalam menangkap pola jangka panjang data historis [10][6][9][11][12]. Pada implementasi kedalam bahasa pemrograman Python dipergunakan beberapa library dalam proses pemodelan diantaranya Pandas untuk manipulasi data dan mengelompokan data, NumPy difungsikan untuk komputasi numerik, Scikit-learn untuk pra-pemrosesan data seperti melakukan normalisasi, serta untuk melakukan evaluasi terhadap model yang dibangun menggunakan RMSE, MAE, dan MAPE. Kemudian terdapat library Matplotlib dan Seaborn untuk melakukan visualisasi data sedangkan TensorFlow dan Keras dipergunakan untuk inti penelitian yaitu membangun dan melatih model LSTM.

2.1. Definisi Infalsi

Laju inflasi merupakan salah satu fenomena ekonomi yang sangat signifikan dan terjadi di hampir setiap negara di dunia. Secara singkat, laju inflasi diartikan sebagai kenaikan harga barang

secara umum dan berkelanjutan. Ini tidak berarti bahwa semua harga barang naik dengan persentase yang sama atau pada waktu yang bersamaan, namun yang menjadi ciri utama laju inflasi adalah adanya tren, kenaikan harga secara umum dan terus menerus dalam periode waktu yang tertentu. Kenaikan harga yang hanya terjadi sekali, meskipun dalam jumlah yang besar, tidak dapat dikategorikan sebagai laju inflasi [13][14].

2.2. Pengeluaran Pemerintah

Pengeluaran pemerintah mencakup seluruh pengeluaran konsumsi yang dilakukan oleh pemerintah. Terdapat dua jenis konsumsi pemerintah, yaitu konsumsi rutin dan konsumsi untuk pembangunan. Pengeluaran ini merupakan upaya pemerintah dalam mengelola perekonomian, yang tercermin dalam alokasi anggaran tahunan, seperti APBN untuk pengeluaran negara secara nasional dan APBD untuk pengeluaran dalam lingkup daerah atau regional. Dalam hal ini, data pengeluaran yang digunakan adalah pengeluaran tahunan pemerintah kota Ternate tahun 2018 sampai dengan tahun 2024 [15].

2.3. Hubungan Inflasi dan Pengeluaran Pemerintah

Pengeluaran pemerintah memainkan peran penting dalam menentukan kinerja ekonomi suatu daerah. Ketika pemerintah memprioritaskan pertumbuhan ekonomi, hal ini dapat memicu peningkatan laju inflasi. Tingginya laju inflasi dapat membawa dampak negatif pada perekonomian daerah secara keseluruhan dengan persamaan untuk menghitung inflasi dijabarkan sebagai berikut :

$$\text{Laju_Inflasi} = \frac{IHK_t - IHK_{t-1}}{IHK_{t-1}} \times 100\%$$

dengan

$$\begin{aligned} IHK_t &= \text{Indeks harga konsumen Tahun / Bulan } (t) \\ IHK_{t-1} &= \text{Indeks harga konsumen Tahun / Bulan } (t - 1) \end{aligned}$$

Contoh Perhitungan Inflasi Tahunan Misalkan kita memiliki data IHK sebagai berikut:

IHK pada bulan Mei 2023 = 114,86

IHK pada bulan Mei 2022 = 108,66

Langkah-langkah perhitungan

1. Tentukan IHK pada dua periode yang dibandingkan:

IHK pada Mei 2023 = 114, 86,

IHK pada Mei 2022 = 108, 66.

2. Masukkan nilai-nilai tersebut ke dalam rumus laju inflasi:

$$\text{Laju inflasi} = \frac{IHK \text{ pada Mei } 2023 - IHK \text{ pada Mei } 2022}{IHK \text{ pada Mei } 2022} \times 100\%$$

3. Langkah perhitungan :

$$\text{Laju Inflasi} = \frac{(114,86 - 108,66)}{108,66} \times 100\% = 5,71\%.$$

Hasil laju inflasi dari Mei 2022 ke Mei 2023 adalah 5,71%. Hal itu berarti harga barang dan jasa secara umum mengalami kenaikan sebesar 5,71% selama periode satu tahun tersebut [16].

2.4. Recurrent Neural Network (RNN)

Sebuah jaringan saraf berulang (*Recurrent Neural Network* atau RNN) adalah jaringan yang memiliki siklus di dalam koneksi

jaringannya, yang berarti bahwa kemampuan dalam memproses, dipanggil berulang - ulang dengan hasil yang dapat menangani *input* dan *output* variable yang bervariasi. Nilai yang didapat, secara langsung atau tidak langsung bergantung pada *output* sebelumnya dari layer tertentu untuk penggunaan sebagai input untuk memprediksi nilai *output* yang baru [7]. RNN memiliki struktur yang digunakan untuk data berbentuk sekuensial seperti representasi pada fig. 2 [17].

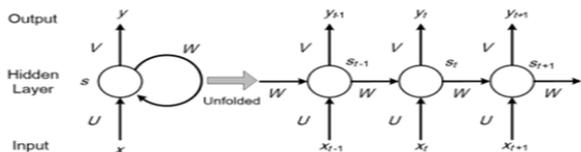


Figure 2. Recurrent Neural Network (RNN)

2.5. Long Short Term Memory (LSTM)

Long Short Term Memory (LSTM) pertama kali di perkenalkan pada tahun 1997 oleh Hochreiter dan Schmidhuber. LSTM dikenal sebagai jaringan saraf dengan arsitektur yang sangat fleksibel, memungkinkan bentuknya sesuai dengan kebutuhan aplikasi tertentu. LSTM merupakan varian dari RNN, yang dirancang khusus untuk menangani data berurutan. Namun demikian, RNN memiliki masalah dengan *finishing* dan *exploding gradient*, yang terjadi ketika rentang nilai yang mengalir dari satu lapisan ke lapisan berikutnya mengalami perubahan signifikan [9]. Lapisan tersebut dalam jaringan LSTM terdiri dari sel memori, dan setiap sel memori di lengkapi dengan tiga jenis gate diantaranya *Input gate*, *Forget gate*, dan *Output gate* [18]. *Input gate* berfungsi untuk mengatur seberapa banyak informasi yang akan disimpan dalam sel memori, sehingga mencegah penyimpanan data yang tidak relevan. *Forget gate* mengendalikan seberapa besar proporsi yang tetap dalam sel memori. *Output gate* menentukan seberapa banyak informasi dari yang digunakan untuk menghasilkan memori untuk menghasilkan *output* [19] yang direpresentasikan pada fig. 3.

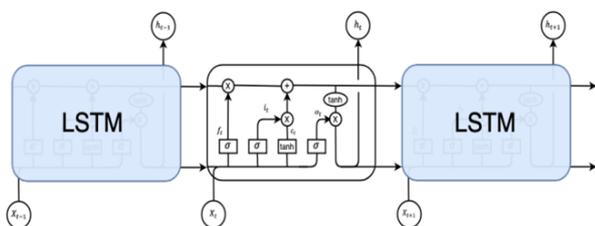


Figure 3. Arsitektur Long Short Term Memory (LSTM)

2.6. Model LSTM

Recurrent Neural Network (RNN) rentan terhadap *vanishing* dan *exploding gradient* sehingga LSTM diperkenalkan dan menjadi salah satu varian paling populer dari RNN. LSTM dengan arsitektur *memory cell* memungkinkan metode ini bisa memilih informasi mana yang harus dipertahankan dan mana yang harus dilupakan, membuat LSTM lebih robust terhadap gangguan yang tidak berkaitan, secara lengkap, LSTM dengan hidden state (*ht*)

dihitung menggunakan persamaan berikut [20]:

$$i_t = \sigma(W_i x_t + H_i h_{t-1} + b_i), \tag{1}$$

$$f_t = \sigma(W_f x_t + H_f h_{t-1} + b_f), \tag{2}$$

$$o_t = \sigma(W_o x_t + H_o h_{t-1} + b_o), \tag{3}$$

$$\tilde{c}_t = \tanh(W_c x_t + H_c h_{t-1} + b_i), \tag{4}$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t, \tag{5}$$

$$h_t = \tanh(c_t) * o_t, \tag{6}$$

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \tag{7}$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \tag{8}$$

dengan

- i_t (Input Gate) = informasi yang diperbarui dalam *cell*,
- f_t (Forget Gate) = informasi yang diturunkan dari *cell*,
- o_t (Output Gate) = informasi yang keluar,
- \tilde{c}_t = nilai *state* dari *memory cell* pada waktu t ,
- c_t = *state* dari *memory cell* saat ini pada waktu t , deng
- h_t = nilai keluar yang telah difilter *output gate*,
- σ = rentang nilai antara 0 dan 1,
- \tanh = rentang nilai antara -1 dan 1,

sisi kanan persamaan didefinisikan sebagai berikut:

x_t = masukan nilai *memory cell* pada waktu t .
 $W_i, W_f, W_o, W_c, H_i, H_f, H_o$ dan H_c merupakan matriks pembobotan.

b_i, b_f, b_o dan b_c adalah vektor bias.

Terhadap model LSTM yang dibangun memiliki arsitektur dengan 1 layer LSTM dan 1 layer dense. Parameter pelatihan terdiri dari 100 *epoch*, *learning rate* sebesar 0,001 dan *batch size* sebesar 32. Untuk meningkatkan kinerja model, nantinya dilakukan dan akan ditampilkan pada hasil penelitian tentang penyesuaian terhadap *hyperparameter* dengan pendekatan *Grid Search*, khususnya pada kombinasi nilai *bact size*, *learning rate*, dan jumlah *neuron* pada *hidden layer*.

2.7. Preprocessing Data

Proses preprosesing data, dilakukan dengan normalisasi data set menggunakan teknik min – max scaler dari sklearn [23]. Teknik ini mengubah nilai aktual menjadi nilai dalam rentang interval tertentu. Dalam penelitian ini rentang interval dibagi menjadi interval [0,1] untuk memperoleh hasil prediksi yang optimal. Berikut adalah rumus yang digunakan untuk normalisasi yaitu

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{9}$$

dengan

- x' = Nilai hasil normalisasi,
- x = Nilai data aktual yang akan normalisasi,
- x_{min} = Nilai minimum data aktual,
- x_{max} = Nilai maximum data aktual.

2.8. Mengukur Akurasi Prediksi

Metode prediksi yang efektif adalah metode yang mampu menghasilkan prediksi dengan kesalahan minimal atau dengan nilai yang terkecil [21]. Validasi suatu metode prediksi sangat bergantung pada indikator – indikator pengukuran akurasi. Ada berbagai metode yang dapat digunakan untuk mengukur tingkat akurasi prediksi diantaranya-Nya Root Mean Squared Error, Mean Absolute Error, dan Mean Absolute Percentage Error yang dipergunakan dalam penelitian ini. Untuk menghindari overfitting dalam hasil yang didapatkan yaitu kondisi dimana model terlalu cocok dengan data latih dan gagal menggeneralisasi ke data baru, maka pada penelitian ini diberlakukan split validation merupakan teknik validasi model prediktif untuk membagi data set menjadi 2 bagian yaitu data latih dan data uji tujuannya untuk menilai kinerja model pada data yang tidak pernah dilihat selama pelatihan [22]. Tidak hanya itu terhadap penggunaan data time-series penelitian ini pembagian data tidak dilakukan secara acak dikarenakan waktu merupakan hal yang penting sehingga data masa depan tidak boleh dipergunakan untuk memprediksi masa lalu. Dengan mekanisme penjabaran 60% pembagian data terhadap data 2018 -2021 digunakan untuk pelatihan dan sisanya 2022-2024 untuk pengujiannya. 70% pembagian data terhadap data 2018-2022 digunakan untuk pelatihan dan sisanya untuk pengujian . mekanisme ini dilakukan hingga mencapai 90% yang mana masing masing konfigurasi diulang dalam beberapa iterasi untuk memeriksa stabilitas model [23].

2.8. Root Mean Squared Error (RMSE)

RMSE menghitung rata – rata dari selisih kuadrat antara nilai prediksi dan nilai aktual, kemudian mengambil akar kuadratnya. Semakin kecil nilai RMSE, semakin baik kualitas model tersebut. RMSE sering digunakan sebagai ukuran statistik standar untuk mengevaluasi kinerja model dalam berbagai penelitian [24]. Adapun untuk menghitung rumus RMSE adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_i^n (\tilde{y}_i - y_i)^2} \tag{10}$$

dengan

- \tilde{y}_i = hasil peramalan,
- y_i = nilai aktual,
- n = ukuran sampel (*sample size*),

2.8. Mean Absolute Error (MAE)

Rata-rata absolut dari selisih antara data prediksi dan data aktual menunjukkan besarnya kesalahan prediksi yang dihasilkan. MAE adalah salah satu ukuran metrik berguna lainnya yang banyak digunakan untuk evaluasi model [25]. Perhitungan Mean Absolute Error dapat dilihat pada rumus di bawah ini [26]

$$MAE = \frac{1}{n} \sum_i^n |\tilde{y}_i - y_i| \tag{11}$$

dengan

- \tilde{y}_i = hasil peramalan,
- y_i = nilai aktual,
- n = ukuran sampel (*sample size*),

Dalam hal ini nilai RMSE dan MAE yang lebih rendah (mendekati nol) menunjukkan bahwa model prediksi lebih akurat, karena rata-rata kesalahan absolutnya kecil dan nilai RMSE

dan MAE yang lebih tinggi menunjukkan bahwa model prediksi kurang akurat, karena rata-rata kesalahan absolutnya besar dan nilai error yang besar akan berpengaruh.

2.8. Mean Absolute Percentage Error (MAPE)

Teknik penilaian lain dalam ilmu data adalah MAPE. Rata-rata variasi antara nilai yang diharapkan dan nilai aktual ditentukan oleh MAPE. Semakin kecil nilai MAPE semakin baik kualitas model tersebut [27]. Menurut Riset Nasional Council (1980), setiap ringkasan ukuran kesalahan harus memenuhi lima kriteria dasar yaitu pengukuran validitas, reliabilitas, kemudahan interpretasi, kejelasan penyajian, dan dukungan statistik evaluasi. MAPE memenuhi sebagian besar kriteria ini [28]. Rumus MAPE didefinisikan sebagai berikut

$$MAPE = 100 \times \frac{1}{n} \sum_i^n \left| \frac{\tilde{y}_i - y_i}{y_i} \right| \tag{12}$$

dengan

- \tilde{y}_i = hasil peramalan,
- y_i = nilai aktual,
- n = ukuran sampel (*sample size*),

2.9. Analisis Time Series

Teknik analisis berdasarkan data atau observasi yang menekankan pada waktu atau urutan kronologis dari variabel yang diamati disebut analisis deret waktu. Data yang berubahnya dipengaruhi oleh waktu atau pengamatan sebelumnya sangat diuntungkan oleh studi ini. Sejak awal kemunculannya, analisis deret waktu telah digunakan secara luas di berbagai industri, termasuk perbankan, ekonomi, dan transportasi [29]. fig. 4 menjelaskan metode pengerjaan data inflasi dengan LSTM.

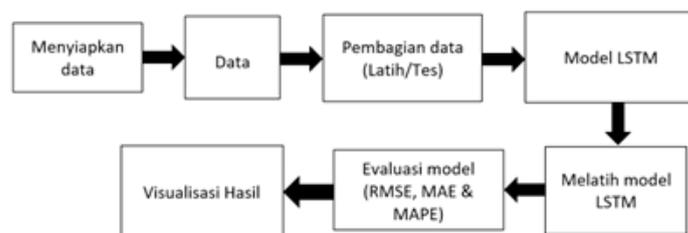


Figure 4. Skema Metode Pengerjaan

2.10. Kriteria Pemilihan Model Terbaik

Pemilihan model terbaik untuk data inflasi dan pengeluaran dilakukan dengan menggunakan nilai MAPE. Nilai MAPE pada data latih digunakan untuk menilai ketepatan estimasi model, sementara nilai MAPE pada data uji menunjukkan ketepatan ramalan model. MAPE dihitung dengan membagi rata – rata persentase nilai-nilai absolut residual pada setiap periode dengan nilai aktualnya [30]. table 1 menunjukkan kriteria model terbaik yang diukur dengan MAPE.

3. Hasil dan Pembahasan

Visualisasi data yang dilakukan sebagai gambaran umum dari data yang digunakan yaitu pada data laju inflasi dan pengeluaran dari bulan Januari tahun 2018 sampai bulan Mei tahun 2024. fig. 5 menunjukkan visualisasi data inflasi Kota Ternate antara bulan Januari Tahun 2018 sampai bulan Mei Tahun 2024.

Table 1. Kriteria MAPE pada Data Inflasi dan Pengeluaran Kota Ternate

MAPE (%)	Tingkat Akurasi
$0 \leq MAPE < 10$	Sangat Baik
$10 \leq MAPE < 25$	Baik
$25 \leq MAPE < 50$	Kurang Baik
$MAPE \geq 50$	Tidak Baik

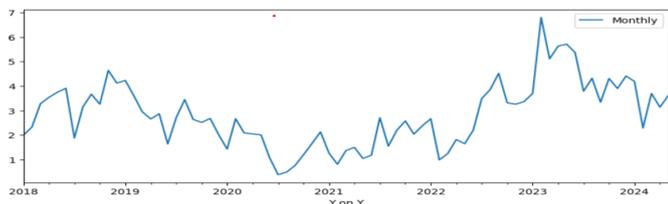


Figure 5. Visualisasi Data Inflasi Kota Ternate Antara Tahun 2018-2024

3.1. Pra-pemrosesan Data Inflasi

Pra-pemrosesan data dilakukan agar dapat meningkatkan kualitas data sehingga model yang dibangun lebih akurat dan efisien serta format data menjadi sesuai. Langkah yang dilakukan pada pra-pemrosesan data yaitu membagi data menjadi data latih dan data uji dengan proporsi 8:2 atau 80 % adalah data latih dan 20 % adalah data uji. Selanjutnya melakukan normalisasi data sehingga dalam range interval [0,1].

3.1. Evaluasi Model Inflasi

Setelah melakukan processing data dan menemukan hasil prediksi, maka hasil setiap model diukur dengan *Root mean squared error* (RMSE), *Mean Absolute Percentage Error* (MAPE) dan *Mean Absolute Error* (MAE) yang direpresentasikan pada **table 2**.

Table 2. Hasil Uji dari Setiap Model

Ukuran Keباikan	Nilai
RMSE	0.8788
MAE	0.7713
MAPE	19.9299

Dari hasil uji dengan persentase 80 % data latih dan 20 % data uji yang dapat dilihat pada ??, menggunakan 20 neuron dan 200 epoch maka nilai akurasi MAPE sebesar 19.9299 %.

3.1. Visualisasi Model Terbaik Inflasi

fig. 6 yang mengilustrasikan perbandingan data asli yang berwarna biru dengan data latih (warna orange) dan data uji (warna hijau) yang diambil dari model terbaik dengan 80 % data latih dan 20 % data uji. Pada fig. 6, dapat dilihat bahwa model yang dibentuk dapat menghasilkan output yang hampir sesuai. Hal tersebut dilihat dari pola data prediksi yang mengikuti pola yang dibentuk oleh data asli. Data asli berwarna biru dan data prediksi berwarna orange. Dari data berwarna hijau, dapat dilihat data hasil prediksi model LSTM kota Ternate pada tahun berikutnya.

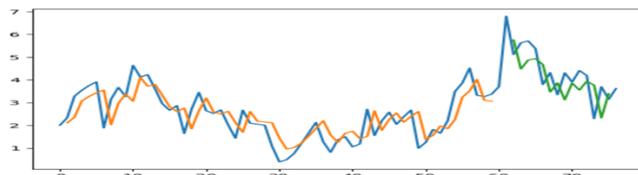


Figure 6. Model LSTM Data Inflasi Kota Ternate

3.2. Data Laju Inflasi dan Pengeluaran

Hal yang sama dapat dilakukan pada data laju inflasi dan pengeluaran. *Preprocessing* data dapat dilakukan agar dapat meningkatkan kualitas data sehingga model yang dibangun dapat lebih akurat dan efisien serta format data menjadi sesuai. Langkah yang sama dilakukan pada *preprocessing* data inflasi dan pengeluaran yaitu membagi data menjadi data latih dan data uji dengan proporsi 8:2 dengan 80 % adalah data latih dan 20 % adalah data uji. Untuk mencegah terjadinya *overfitting* dan memastikan model melakukan generalisasi dengan baik terhadap data baru, metode *split validation* diterapkan secara sistematis. Selain itu data kemudian dinormalisasi dalam range interval [0,1] menggunakan teknik *Min-Max normalization* agar mendukung konvergensi model yang lebih cepat dan stabil.

3.3. Evaluasi Model Inflasi dan Pengeluaran

Hasil dari analisis dalam persentase diukur oleh *Root mean squared error* (RMSE), *Mean Absolute Percentage Error* (MAPE) dan *Mean Absolute Error* (MAE). Nilai RMSE, MAPE dan MAE dapat dilihat pada **table 3**. Dari hasil uji dengan persentase 80 % data latih dan 20 % data uji yang dapat dilihat pada **table 3**, dengan menggunakan 20 neuron dan 500 epoch maka didapatkan nilai akurasi MAPE sebesar 20.1927 %. Hasil skenario penggunaan dataset untuk eksperimen disiapkan berdasarkan komposisi data latih dan data uji dalam persentase dapat dilihat pada **table 4**.

Table 3. Hasil dari Analisis dalam Persentase

Ukuran Keباikan	Nilai
RMSE	0.8461
MAE	0.7148
MAPE	20.1927

Table 4. Hasil skenario data set dalam persentase

Persentase (Latih/Uji)	RMSE	MAE	MAPE
90%-10%	0.9280	0.7920	25.2172
80%-20%	0.8460	0.7148	20.1927
70%-30%	1.6350	1.3517	29.9599
60%-40%	1.5310	1.2293	33.276

Dari hasil skenario data set pada **table 4**, untuk data laju inflasi dan pengeluaran, dapat dilihat dari keseluruhan nilai memiliki persentase terbaik, nilai MAPE adalah 20.1927 % juga nilai RMSE dan MAE memiliki nilai yang relatif kecil. Hal tersebut mengakibatkan tingkat akurasi prediksi menjadi lebih baik untuk data inflasi dan pengeluaran.

3.3. Visualisasi Model Terbaik Inflasi dan Pengeluaran

fig. 7 mengilustrasikan perbandingan data asli yang berwarna biru dengan data prediksi yang berwarna orange diambil dari model terbaik dengan 80 % data latih dan 20 % data uji untuk data laju inflasi dan pengeluaran. fig. 7 dapat dilihat bahwa model yang dibentuk dapat menghasilkan output yang hampir sesuai. Hal tersebut dilihat dari pola data prediksi yang mengikuti pola yang dibentuk oleh data original. Data original berwarna biru dan data prediksi berwarna orange dan hijau. Dari data dapat dilihat data hasil prediksi model LSTM kota Ternate pada tahun berikutnya. table 5 menunjukkan nilai prediksi lima bulan berikutnya laju inflasi dan pengeluaran kota Ternate.

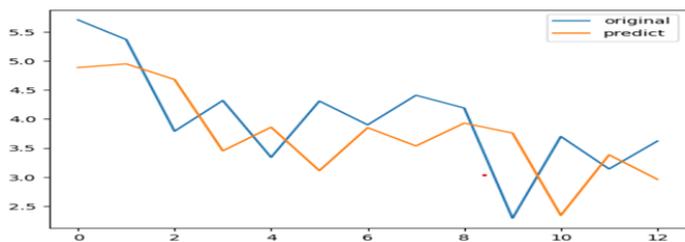


Figure 7. Model LSTM Data Inflasi dan Pengeluaran Kota Ternate

Table 5. Nilai Prediksi Data Inflasi dan Pengeluaran Kota Ternate

Bulan	1	2	3	4	5
Nilai	3.6514	3.5042	2.2710	3.1791	2.8130

3.3. Iterasi Data Laju Inflasi dan Pengeluaran

Berdasarkan hasil validasi berlapis terhadap berbagai proporsi data latih, dilakukan evaluasi menggunakan metrik RMSE, MAE, dan MAPE untuk memperoleh model prediksi yang baik. table 6, table 7, table 8, dan table 9 menampilkan hasil rata-rata dari iterasi model LSTM terhadap data laju inflasi dan pengeluaran, menggunakan teknik split validation dengan membagi data temporal menjadi beberapa sub set validasi yang berurutan, sehingga model diuji pada data yang tidak terlihat secara bertahap tanpa mencampur urutan waktu. Berdasarkan perlakuan ini, ditemukan hasil terbaik diperoleh pada proporsi data latih 80% dengan parameter neuron sebanyak 20 dan epoch sebanyak 500. Rata-rata nilai akurasi yang dihasilkan cukup stabil, dengan RMSE sebesar 0.9275, MAE sebesar 0.8369, dan MAPE sebesar 20.13% menunjukkan bahwa model memiliki performa prediktif yang baik dan tidak mengalami overfitting terhadap data latih.

Table 6. Iterasi dengan Persentase 60%

Iterasi ke	RMSE	MAE	MAPE
1	1.4810	1.1751	32.1987
2	1.5103	1.1823	31.7450
3	1.5091	1.1654	31.0895
4	1.4876	1.1598	30.8942
5	1.4952	1.1712	31.2215
6	1.5174	1.1918	32.0184
Rata-rata	1.5001	1.1743	31.6777

Table 7. Iterasi dengan Persentase 70%

Iterasi ke	RMSE	MAE	MAPE
1	1.7140	1.4302	30.6784
2	1.7456	1.4597	32.1178
3	1.7430	1.4508	31.6467
4	1.7325	1.4405	31.2081
5	1.7210	1.4331	30.9014
6	1.7482	1.4472	31.4009
Rata-rata	1.7340	1.4472	31.4009

Table 8. Iterasi dengan Persentase 80%

Iterasi ke	RMSE	MAE	MAPE
1	0.9170	0.8370	20.4713
2	0.9261	0.8325	19.8421
3	0.9395	0.8411	20.1690
4	0.9342	0.8475	20.6812
5	0.9164	0.8297	19.9881
6	0.9119	0.8335	19.8127
Rata-rata	0.9275	0.8369	20.1275

Table 9. Iterasi dengan Persentase 90%

Iterasi ke	RMSE	MAE	MAPE
1	0.7923	0.6081	20.2871
2	0.7705	0.5852	18.9270
3	0.7755	0.5810	16.7475
4	0.7880	0.5950	17.5043
5	0.7992	0.6034	18.1402
6	0.7901	0.5997	18.4123
Rata-rata	0.7860	0.5954	18.3364

4. Kesimpulan

Model Long Short-Term Memory (LSTM) memiliki kemampuan yang baik dalam memprediksi laju inflasi tahunan (Year on Year) di Kota Ternate. Penelitian ini menggunakan data inflasi dan pengeluaran pemerintah Kota Ternate yang diperoleh dari Badan Pusat Statistik (BPS) untuk periode Januari 2018 hingga Mei 2024. Dengan konfigurasi data latih sebesar 80%, jumlah neuron sebanyak 20, dan 200 epoch, diperoleh hasil evaluasi model berupa RMSE sebesar 0.8788, MAE sebesar 0.7713, dan MAPE sebesar 19.9299%. Selain itu, ketika model dilatih dengan mempertimbangkan data inflasi dan data pengeluaran secara bersamaan, dengan konfigurasi data latih 80%, jumlah neuron 20, dan 500 dengan menggunakan pendekatan split validation hasil prediksi menunjukkan nilai rata-rata RMSE sebesar 0.9275, MAE sebesar 0.8369, dan MAPE sebesar 20.13%. Hasil ini mengindikasikan bahwa LSTM mampu menangkap pola dari data historis dan melakukan prediksi inflasi dengan tingkat kesalahan yang cukup rendah.

Penerapan split validation terhadap masing-masing konfigurasi iterasi menunjukkan kestabilan kinerja model dalam berbagai skenario pembagian data uji sekaligus memperkuat validitas hasil yang diperoleh. Penelitian selanjutnya disarankan untuk mengeksplorasi arsitektur dan parameter lain dalam model LSTM, seperti jumlah neuron, jumlah layer tersembunyi, serta variasi dalam fungsi aktivasi dan algoritma optimasi, guna

meningkatkan akurasi prediksi. Selain itu, penggunaan teknik optimasi tambahan untuk meningkatkan kinerja arsitektur LSTM juga dapat menjadi pendekatan yang potensial, serta membandingkan hasilnya dengan model *deep learning* lainnya agar diperoleh solusi prediktif yang lebih optimal.

References

- [1] Suseno and Astiyah, *Inflasi*. Bank Indonesia, 2009.
- [2] M. H. Meiditambua, S. A. Centauri, and M. R. Fahlevi, "Pengaruh inflasi terhadap pertumbuhan ekonomi: perspektif indonesia," *Jurnal Acitya Ardana*, vol. 3, no. 1, pp. 17–26, 2023.
- [3] S. Djambek, "Faktor dominan mempengaruhi inflasi di indonesia," *Jurnal Ekonomi Pembangunan*, vol. 6, no. 1, pp. 23–38, 2008.
- [4] E. F. B. Simanungkalit, "Pengaruh inflasi terhadap pertumbuhan ekonomi di indonesia," *Journal of Management: Small and Medium Enterprises (SMEs)*, vol. 13, no. 3, pp. 327–340, 2020.
- [5] R. Kurniawan, "Hubungan inflasi indeks harga konsumen, tingkat suku bunga, produk domestik bruto, serta nilai tukar di indonesia," *Populer: Jurnal Penelitian Mahasiswa*, vol. 1, no. 4, pp. 49–61, 2022.
- [6] B. A. H. Kholifatullah and A. Prihanto, "Penerapan metode long short term memory untuk klasifikasi pada hate speech," *Journal of Informatics and Computer Science (JINACS)*, pp. 292–297, 2023.
- [7] S. Zahara, M. B. Ilmiddafiq *et al.*, "Prediksi indeks harga konsumen menggunakan metode long short term memory (lstm) berbasis cloud computing," *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, vol. 3, no. 3, pp. 357–363, 2019.
- [8] S. li, "Inflation forecasting using a hybrid lstm-sarima model based on discrete wavelet transform," *Advances in Economics Management and Political Sciences*, vol. 73, no. 1, 2024.
- [9] L. Wiranda and M. Sadikin, "Penerapan long short term memory pada data time series untuk memprediksi penjualan produk pt. metiska farma," *Jurnal Nasional Pendidikan Teknik Informatika: JANAPATI*, vol. 8, no. 3, pp. 184–196, 2019.
- [10] E. Arif, E. Herlinawati, D. Devianto, M. Yollanda, and D. Permana, "Hybridization of long short-term memory neural network in fractional time series modeling of inflation," *Frontiers in big Data*, vol. 6, p. 1282541, 2024.
- [11] X.-H. Le, H. V. Ho, G. Lee, and S. Jung, "Application of long short-term memory (lstm) neural network for flood forecasting," *Water*, vol. 11, no. 7, p. 1387, 2019.
- [12] M. M. Taye, "Understanding of machine learning with deep learning: architectures, workflow, applications and future directions," *Computers*, vol. 12, no. 5, p. 91, 2023.
- [13] I. L. Widiastuti, "Pengaruh jumlah uang beredar terhadap inflasi di indonesia bulan januari 2001–desember 2011: Pendekatan error correction model (ecm)," Ph.D. dissertation, UAJY, 2012.
- [14] L. D. Arumningsih and M. Y. Darsyah, "Peramalan indeks harga konsumen kota malang tahun 2014–2016 dengan menggunakan metode moving average dan exponential smoothing holt-winter," in *Prosiding Seminar Nasional Mahasiswa Unimus*, vol. 1, 2018.
- [15] B. K. MANDA, "Analisis empiris hubungan kausalitas antara pengeluaran pemerintah dan inflasi di indonesia," *FAKULTAS EKONOMI DAN BISNIS*, 2023.
- [16] H. S. Bambang *et al.*, "Analisis perilaku inflasi negara indonesia tinjauan historis ekonomi dalam pusara ekonomi kerakyatan," 2023.
- [17] M. R. Firmansyah, R. Ilyas, and F. Kasyidi, "Klasifikasi kalimat ilmiah menggunakan recurrent neural network," in *Prosiding Industrial Research Workshop and National Seminar*, vol. 11, no. 1, 2020, pp. 488–495.
- [18] A. Z. Arham, "Klasifikasi ulasan buku menggunakan algoritma convolutional neural network-long short term memory," Ph.D. dissertation, Institut Teknologi Sepuluh Nopember, 2018.
- [19] D. Aisyah, T. W. Purboyo, and M. Kallista, "Prediksi penderita tuberkulosis dengan algoritma long short-term memory," *eProceedings of Engineering*, vol. 10, no. 1, 2023.
- [20] T. E. Sutanto *et al.*, "Analisis model lstm dalam peramalan sistem dinamis chaotic persamaan diferensial keuangan," B.S. thesis, Fakultas Sains dan Teknologi UIN Syarif Hidayatullah Jakarta, 2023.
- [21] A. Afriyudi, "Prediksi jumlah siswa baru dengan menggunakan metode exponential smoothing (studi kasus: Smk ethika Palembang)," *PREDIKSI JUMLAH SISWA BARU DENGAN MENGGUNAKAN METODE EXPONENTIAL SMOOTHING (STUDI KASUS: SMK ETHIKA PALEMBANG)*, 2022.
- [22] R. Oktafiani, A. Hermawan, and D. Avianto, "Pengaruh komposisi split data terhadap performa klasifikasi penyakit kanker payudara menggunakan algoritma machine learning," *Jurnal Sains dan Informatika*, pp. 19–28, 2023.
- [23] X. Ying, "An overview of overfitting and its solutions," in *Journal of physics: Conference series*, vol. 1168. IOP Publishing, 2019, p. 022022.
- [24] T. Chai and R. R. Draxler, "Root mean square error (rmse) or mean absolute error (mae)?—arguments against avoiding rmse in the literature," *Geoscientific model development*, vol. 7, no. 3, pp. 1247–1250, 2014.
- [25] T. O. Hodson, "Root mean square error (rmse) or mean absolute error (mae): When to use them or not," *Geoscientific Model Development Discussions*, vol. 2022, pp. 1–10, 2022.
- [26] R. Luthfiansyah and B. Wasito, "Penerapan teknik deep learning (long short term memory) dan pendekatan klasik (regresi linier) dalam prediksi pergerakan saham bri," *Jurnal Informatika dan Bisnis*, vol. 12, no. 2, pp. 42–54, 2023.
- [27] A. Khumaidi and I. Ayu Nirmala, "Algoritma long short term memory dengan hyperparameter tuning: Prediksi penjualan produk," 2022.
- [28] D. A. Swanson, J. Tayman, and T. Bryan, "Mape-r: a rescaled measure of accuracy for cross-sectional subnational population forecasts," *Journal of Population Research*, vol. 28, pp. 225–243, 2011.
- [29] B. D. Prasetya, F. S. Pamungkas, and I. Kharisudin, "Pemodelan dan peramalan data saham dengan analisis time series menggunakan python," in *PRISMA, Prosiding Seminar Nasional Matematika*, vol. 3, 2020, pp. 714–718.
- [30] D. I. Purnama and O. P. Hendarsin, "Peramalan jumlah penumpang berangkat melalui transportasi udara di sulawesi tengah menggunakan support vector regression (svr)," *Jambura Journal of Mathematics*, vol. 2, no. 2, pp. 49–59, 2020.