

Implementasi Algoritma Long Short-Term Memory Untuk Prediksi Tingkat Inflasi di Jawa Timur

Moh. Angga Ardiyansyah^{1*}, Muhammad Muharrom Al Haromainy², Achmad Junaidi³

^{1,2,3} Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur

²muhammad.muharrom.if@upnjatim.ac.id

³achmadjunaidi.if@upnjatim.ac.id

*Corresponding author email: 21081010004@student.upnjatim.ac.id

Abstrak - Stabilitas ekonomi di Jawa Timur, sebagai salah satu pilar ekonomi nasional, sangat dipengaruhi oleh tingkat inflasi yang fluktuatif. Prediksi inflasi yang akurat sangat penting untuk perumusan kebijakan, namun metode tradisional seperti ARIMA seringkali kesulitan menangani data deret waktu yang kompleks dan dependensi jangka panjang. Penelitian ini bertujuan untuk mengimplementasikan algoritma *Long Short-Term Memory* (LSTM) guna menghasilkan model prediksi inflasi yang lebih akurat dan adaptif di Jawa Timur. Penelitian ini menggunakan data inflasi Year-on-Year (YoY) bulanan univariat dari BPS Jawa Timur periode Januari 2005 hingga Desember 2024. Metode penelitian meliputi pra-pemrosesan data menggunakan *Min-Max Scaler* dan *Sliding Window*, serta pengujian dua skenario hyperparameter (epoch, layer, dan neuron). Evaluasi model menggunakan metrik *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Hasil pengujian menunjukkan bahwa arsitektur LSTM 2 layer dengan 128 neuron pada setiap layer dan 100 epoch menghasilkan performa terbaik, dengan nilai RMSE 1,1986, MAE 0,6209, dan MAPE 14,74%. Model LSTM ini terbukti secara signifikan mengungguli model pembandingan ARIMA (RMSE 1,9666) dan *Triple Exponential Smoothing* (RMSE 2,5605). Penelitian ini menyimpulkan bahwa LSTM adalah model yang andal dan layak untuk memprediksi tingkat inflasi di Jawa Timur serta dapat menjadi baseline untuk penelitian selanjutnya.

Kata Kunci – Inflasi, Long Short-Term Memory, Prediksi, Data Deret Waktu.

I. PENDAHULUAN

Visi Indonesia Emas 1945 merupakan sebuah agenda pembangunan jangka panjang yang menempatkan pembangunan berkelanjutan sebagai tujuan utama. Visi ini telah diatur dalam Undang-undang No. 59 Tahun 2024 Tentang Rencana Pembangunan Jangka Panjang Nasional Tahun 2025-2045. Salah satu misi dari 17 arah pembangunan visi tersebut adalah Transformasi ekonomi yang kuat dan stabil. Dalam konteks ini, stabilitas ekonomi yang mencakup stabilitas harga dan nilai tukar memiliki penting sebagai pilar fundamental dalam mewujudkan visi tersebut. Stabilitas krusial ini tidak hanya untuk menjaga kesejahteraan domestik, namun juga untuk menciptakan iklim usaha yang menarik bagi investor, yang juga merupakan mesin penggerak pertumbuhan ekonomi berkelanjutan.

Secara geografis ekonomi, Provinsi Jawa Timur memainkan peran yang sangat penting di Indonesia. Berdasarkan data resmi dari Badan Pusat Statistika (BPS) Provinsi Jawa Timur,

pertumbuhan ekonomi pada tahun triwulan II-2025 mencapai angka 3,09 persen (BPS Jatim, 2025). Oleh karena itu, ketidakstabilan ekonomi di Provinsi ini dapat menimbulkan kekhawatiran dan berpotensi mengganggu stabilitas ekonomi nasional secara keseluruhan. Salah satu indikator kunci yang mencerminkan kestabilan ekonomi adalah Inflasi.

Inflasi didefinisikan sebagai kenaikan harga barang dan jasa secara umum dan terus menerus. Pengendalian inflasi merupakan mandat utama Tata Kelola Pemerintahan yang melibatkan otoritas moneter (Bank Indonesia) dan Pemerintah. Dalam Prosesnya, pengendalian ini dilakukan oleh Tim Pengendalian Inflasi Daerah (TPID) yang bertugas untuk menjaga stabilitas perekonomian pada tingkat daerah. Pembentukan tim ini juga didasari oleh Instruksi Menteri Dalam Negeri Republik Indonesia Nomor 027/1696/SJ tentang menjaga keterjangkauan barang dan jasa di daerah[1]. Inflasi yang tinggi dapat secara drastis menggerus daya beli masyarakat, menciptakan ketidakpastian bagi pelaku usaha, menghambat investasi, dan pada akhirnya mengurangi kesejahteraan.

Untuk mendukung tata kelola pemerintahan, diperlukan sebuah sistem prediksi ekonomi yang andal, terlebih untuk memprediksi tingkat inflasi di wilayah provinsi. Namun, tantangan prediksi inflasi sangat kompleks. Data Inflasi merupakan data deret waktu yang memiliki karakteristik kompleks dan sering dipengaruhi oleh faktor-faktor tertentu, seperti Harga Konsumen, Suku Bunga Sertifikat Bank Indonesia, dan Nilai tukar Rupiah Terhadap Dollar[2]. Dinamika inflasi di Provinsi Jawa Timur menunjukkan adanya fluktuasi yang cukup signifikan. Hal ini dibuktikan secara deskriptif melalui data historis yang dirilis oleh BPS provinsi Jatim. Sebagai contoh, pada inflasi YoY, data inflasi sempat mencapai angka 6,80 persen pada September 2022, kemudian mengalami tren penurunan yang signifikan dan tercatat di angka 3,04 persen pada bulan yang sama di tahun berikutnya atau pada September 2023[3].

Dalam praktiknya, beberapa metode prediksi telah digunakan dalam melakukan prediksi. Sebagai Contoh, penelitian yang dilakukan oleh Ahsan dan Rifai pada tahun 2023 yang membandingkan metode Fuzzy dan ARIMA. Penelitian tersebut menghasilkan sebuah MAPE dari Fuzzy yang mencapai 12.273% dan 24.999% untuk ARIMA[4]. Kemudian Mutiara Nuralifia & Rodiah yang mencoba melakukan analisis perbandingan metode prediksi untuk mencari metode terbaik dan diterapkan pada data inflasi Provinsi Jawa Barat. Pada

penelitian ini ditunjukkan bahwa model ARIMA mendapatkan nilai RMSE sebesar 2,66885 sedangkan Regresi Linier mendapatkan nilai 1,792. Terakhir model *Triple Exponential Smoothing* mendapat nilai loss sebesar 0,1581162 untuk RMSE[5].

Meskipun model-model sebelumnya efektif dalam menangani pola linier, namun model-model tersebut memiliki keterbatasan metodologi yang signifikan. Keterbatasan utama adalah model-model tersebut kesulitan dalam menangkap ketergantungan jangka panjang secara efektif terhadap data deret waktu yang berukuran kompleks dan besar. Kesenjangan penelitian ini menunjukkan adanya kebutuhan mendesak akan inovasi. Menjawab hal tersebut, LSTM dihadirkan sebagai perkembangan RNN standar yang secara khusus mempelajari dependensi jangka panjang dalam data berurutan melalui mekanisme memori internal yang lebih kompleks[6]. Keunggulan utama dari LSTM terletak pada mekanisme gate yang memungkinkannya untuk secara efektif mempelajari dan mengingat pola dari urutan data yang sangat panjang tanpa mengalami masalah vanishing gradient yang umum terjadi pada RNN standar.

Dalam praktiknya, LSTM sudah banyak digunakan dalam melakukan prediksi pada lingkup ekonomi. Sebagai contoh, penelitian yang dilakukan oleh Rizkilloh & Widiyanesti yang pernah menggunakan LSTM untuk memprediksi harga *Cryptocurrency*. Pada penelitian ini nilai loss terkecil yang didapat adalah sebesar 0,544 untuk metrik RMSE[7]. Selain itu, pada penelitian yang dilakukan oleh Sumarjaya & Susilawati juga pernah menerapkan prediksi tingkat inflasi di Bali menggunakan LSTM dan mendapatkan nilai RMSE sebesar 0,554 dengan menggunakan stacked LSTM 2 layer[8].

Berdasarkan tinjauan terhadap beberapa penelitian terdahulu, model LSTM terbukti andal dalam melakukan prediksi data deret waktu di lingkup ekonomi. Meskipun demikian, penerapan model prediktif menggunakan LSTM untuk memprediksi tingkat inflasi di Jawa Timur masih sangat terbatas. Oleh karena itu, penelitian ini akan mencoba menerapkan model LSTM untuk menghasilkan prediksi inflasi yang akurat dan adaptif. Penelitian ini sendiri dilakukan dengan tujuan untuk memprediksi tingkat inflasi dengan memanfaatkan algoritma LSTM. Dengan adanya penelitian ini, diharapkan model dapat membantu menangkap pola-pola kompleks dalam data inflasi. Selain itu, model yang dibangun juga diharapkan dapat membantu dalam perumusan kebijakan daerah dan membantu dalam pengendalian stabilitas inflasi khususnya di Jawa Timur

II. METODE PENELITIAN

Model utama yang digunakan dalam penelitian ini adalah *Long Short-Term Memory* yang merupakan perkembangan dari model *Recurrent Neural Network* dan digunakan untuk mengatasi limitasi utama yang melekat pada RNN konvensional. Model ini dapat mempelajari dan mengingat dependensi jangka panjang dalam data. Model terdiri dari beberapa komponen kunci, antara lain *Cell State* dan *Gate*

Mechanism. Mekanisme gebang yang digunakan dalam penelitian ini terdiri dari 3 gerbang utama, yakni *Forget Gate*, *Input Gate*, dan *Output Gate*.

Penelitian ini mengadopsi pendekatan kuantitatif dengan fokus pada analisis data deret waktu dan peramalan. Proses dilakukan dengan beberapa tahapan. Tahapan-tahapan tersebut antara lain pengumpulan data dan pra-pemrosesan data, perancangan model, pelatihan dan pengujian model, denormalisasi dan evaluasi, dan terakhir analisis hasil serta penarikan kesimpulan. Tahapan pertama dalam penelitian ini adalah pengumpulan data Inflasi Provinsi Jawa Timur. Data yang digunakan dalam penelitian ini adalah data Inflasi Year-on-Year Bulanan Provinsi Jawa Timur dengan ciri berupa data univariat. Pemilihan jenis data Year-on-Year karena jenis data ini digunakan oleh bank sentral untuk merumuskan kebijakan moneter dan menetapkan target inflasi.

Data deret waktu yang telah dikumpulkan selanjutnya perlu dilakukan serangkaian tahap pra-pemrosesan data agar sesuai dan optimal sebagai masukan jaringan syaraf tiruan. Tahapan dimulai dengan pemeriksaan dan pembersihan data. Pada saat data diambil data sudah bersih dan tidak ada beberapa hal yang mengganggu data seperti data hilang atau data duplikat. Oleh karena itu, dapat disimpulkan bahwa data sudah bersih ketika diambil dari situs BPS Jatim. Selanjutnya dilakukan Normalisasi pada data. Hal ini karena model ini sangat sensitif terhadap skala dari data input.

Selanjutnya adalah tahap transformasi data. Tahap ini dilakukan karena umumnya model Supervised Learning memerlukan data dalam format pasangan masukan (X) dan keluaran (y). Sementara itu, data inflasi yang digunakan berbentuk data deret waktu univariat. Pada penelitian ini, metode yang digunakan untuk melakukan transformasi adalah *Sliding Window*. Metode ini bekerja dengan menggeser jendela observasi secara bertahap untuk membentuk pasangan input-output dalam format supervised learning. Secara sederhana proses ini dilakukan dengan cara mengambil data sepanjang nilai timestep sebagai satu set fitur masukan dan 1 bulan untuk target. Jendela ini kemudian bergeser satu langkah ke depan sepanjang data yang digunakan. Setelah proses ini selesai, tahapan selanjutnya adalah pembagian data menjadi data latih dan data uji yang digunakan untuk melatih dan mengevaluasi model secara objektif.

Tahapan selanjutnya adalah perancangan model. Model memiliki 4 lapisan utama, yakni lapisan *input*, lapisan LSTM, lapisan *Dropout*, dan Lapisan *output*. Pada penelitian ini akan diujikan juga 2 skenario lapisan LSTM yakni LSTM 1 lapisan dan 2 lapisan. Setiap lapisan nantinya akan memiliki masing-masing lapisan *Dropout* untuk membantu proses pelatihan agar tidak terjadi *overfitting*.


Setelah model dibangun tahapan selanjutnya adalah proses pelatihan. Proses ini diawali dengan penentuan hyperparameter penelitian yang akan diujikan. Hyperparameter tersebut ditentukan dan dilatih dengan berbagai kombinasi kemudian dicari kombinasi terbaiknya untuk mendapatkan hasil terbaik. Setelah dilatih model akan diuji untuk melihat seberapa efektif

model dapat bekerja dengan data baru. Selanjutnya model akan dievaluasi menggunakan beberapa metrik seperti RMSE, MAE, dan MAPE. Terakhir hasil dari evaluasi tiap skenario pengujian akan dianalisis dan kemudian disimpulkan hasil terbaik dari pengujian.

Untuk memvalidasi keunggulan model LSTM yang diusulkan, penelitian ini juga mengimplementasikan dua metode statistik populer sebagai baseline pembandingan, yakni *Autoregressive Integrated Moving Average* (ARIMA) dan *Triple Exponential Smoothing* (TES). Implementasi ARIMA mengikuti metodologi Box-Jenkins, yang mencakup uji stasioneritas data menggunakan *Augmented Dickey-Fuller* (ADF) serta identifikasi orde model (p,d,q) melalui analisis plot ACF dan PACF. Sementara itu, model TES (Holt-Winters) digunakan untuk menangani data yang memiliki komponen trend dan musiman, dengan menguji varian Aditif dan Pemilihan model ini didasarkan pada penelitian yang dilakukan oleh Nuralifia dan Rodiah yang pernah menggunakan metode serupa untuk melakukan prediksi Inflasi di Jawa Barat[5]. Pada penelitian ini, model ARIMA (1,0,1). Model ini dipilih karena setelah perhitungan stasioneritas, model dianggap sudah stasioner. Kemudian model TES pada penelitian ini diatur dengan nilai smoothing level sebesar 0,9997, smoothing tren sebesar 0,0231, smoothing seasonal 0,001, dan damping tren sebesar 0,8001.

III. HASIL DAN PEMBAHASAN

Langkah pertama dari penelitian ini adalah pengumpulan data. Data yang digunakan dalam penelitian ini adalah data tingkat inflasi YoY di Jawa Timur pada periode Januari 2005-Desember 2024 dengan total data berjumlah 240 data. Data diambil melalui situs web resmi BPS Provinsi Jawa Timur yang dapat diakses secara bebas dan menyediakan data inflasi secara berkala.



Gbr 1 Grafik Tingkat Inflasi di Jawa Timur

Karakteristik yang paling menonjol dari data inflasi adalah fluktuasi dari data tersebut. Pada Gbr 1 ditunjukkan bahwa tingkat inflasi yang terjadi di Jawa Timur mengalami fluktuasi yang sangat dinamis. Hal ini dapat dilihat pada grafik tersebut yang mana tingkat inflasi di Jawa Timur sering kali mengalami guncangan yang ekstrem. Selain itu, ukuran paling representatif dari data ini adalah dengan menggunakan Koefisien Variasi (CV) untuk melihat seberapa fluktuatif data tersebut. Berdasarkan data, diperoleh sebuah nilai CV sebesar 61,08%. Angka ini berada jauh diambang batas volatilitas tinggi yakni

30% dan secara definitif mengonfirmasi bahwa data inflasi Jawa Timur memiliki tingkat fluktuasi yang ekstrem.

Tahapan selanjutnya adalah *pre-processing*. Tahap pertama yang dilakukan adalah melakukan pembersihan data. Tahap ini dimulai dengan melakukan pengecekan data yang hilang. Berdasarkan observasi yang dilakukan data lengkap dan sudah bersih. Selanjutnya adalah melakukan normalisasi. Tahap ini dianggap penting karena akan menentukan hasil prediksi. Teknik normalisasi yang dipilih adalah *Min-Max Scaler*. Teknik ini akan mengubah nilai menjadi di antara 0-1. Setelah dilakukan normalisasi, data diubah bentuknya menjadi berbentuk jendela (*windowing*). Teknik ini akan membuat sebuah jendela dengan jumlah vektor 12 untuk input dan 1 target. Hal ini dilakukan karena merupakan supervised learning dan mengharuskan model mendapat data dalam format input output. Terakhir adalah pembagian data. Dalam penelitian ini, data dibagi dengan rasio train test sebesar 80:20. Dalam proses pelatihan juga nantinya data latih akan diambil sebanyak 20 persen untuk proses validasi.

Dalam penelitian ini, ditentukan beberapa *hyperparameter* yang akan digunakan selama pengujian. *Hyperparameter* yang akan diuji selama penelitian adalah sebagai berikut:

Tabel 1 Hyperparameter yang akan diuji

Jumlah Epoch Maksimal	25
	50
	100
Jumlah Layer & Neuron	64
	128
	64, 64
	64, 128
	128, 64
	128, 128

Pada tabel 1 ditunjukkan beberapa hyperparameter yang akan diuji selama pengujian yang akan dilakukan dengan 2 skenario utama. Hasil terbaik dari setiap skenario akan dianalisis dan dievaluasi menggunakan metrik evaluasi dan parameter terbaik akan digunakan pada skenario selanjutnya. Pengujian pertama akan menguji jumlah epoch maksimal yang akan digunakan selama pelatihan. Jumlah epoch yang akan diujikan antara lain berjumlah 25, 50, dan 100. Beberapa parameter lain yang akan digunakan dalam pelatihan ini adalah LSTM dengan 1 layer dan neuron berjumlah 64. Penentuan jumlah layer dan neuron ini didasarkan pada jumlah layer dan neuron terkecil yang akan diujikan. Hasil terbaik dari pengujian pertama akan digunakan sebagai parameter pada pengujian selanjutnya. Pada pengujian kedua parameter yang diuji adalah jumlah neuron dan layer yang keduanya diujikan bersamaan dengan jumlah pengujian sekitar 6 pengujian.

Tabel 2 Hyperparameter LSTM

Timestep	12
Batch Size	32
Optimizer	Adam (Default)

Selain itu, parameter-parameter lain yang akan digunakan ditunjukkan pada Tabel 2. Timestep senilai 12, Batch size senilai 32 dan Optimizer Adam yang akan diatur secara default

berdasarkan library yang digunakan (0,001). Penentuan nilai Timestep berjumlah 12 didasarkan pada penelitian yang dilakukan oleh Sumarjaya dan Susilawati yang juga menetapkan nilai timestep berjumlah 12[8]. Kemudian penetapan nilai Batch size berukuran 32 dan optimizer Adam mengikuti aturan umum dalam implementasi model LSTM.

Tabel 3 Hasil Pengujian Skenario Pertama

Epoch	RMSE	MAE	MAPE
25	1,4111	0,9707	26,35%
50	1,3193	0,8511	22,04%
100	1,1952	0,6476	15,51%

Skenario pertama adalah menguji berdasarkan jumlah epoch maksimal yang digunakan. Pengujian ini melibatkan beberapa skenario yakni menggunakan epoch sebesar 25, 50, dan 100. Parameter lain yang digunakan menggunakan parameter dasar dengan jumlah layer 1 dan neuron sebesar 64. Hasil dari pengujian ini dapat dilihat pada Tabel 3.

Pada pengujian ini hasil terbaik didapat pada skenario dengan jumlah epoch sebesar 100. Hal ini dapat dilihat dari nilai loss RMSE pada skenario dengan epoch 100 menunjukkan nilai loss sebesar 1,1952. Selain itu, nilai ini juga selaras dengan beberapa metrik lain seperti MAE dan MAPE. Nilai MAE yang didapat oleh pengujian dengan epoch 100 menunjukkan nilai sebesar 0,6476. Nilai ini dinilai lebih baik daripada skenario lain yang hanya mendapat nilai 0,8511 untuk epoch 50 dan 0,9707 untuk epoch sebesar 25. Selain itu nilai MAPE juga menunjukkan nilai persentase loss yang paling kecil dibanding dengan epoch lain. Pada pengujian dengan 100 epoch, nilai MAPE hanya mencapai 15,51%.


Pengujian selanjutnya menguji berdasarkan jumlah layer dan Neuron. Pada pengujian ini model yang digunakan ada 2 macam, yakni model dengan 1 layer dan 2 layer. Selain itu neuron yang digunakan terdiri dari kombinasi neuron dengan jumlah 64 dan 128. Selain itu, jumlah epoch yang digunakan adalah 100 sesuai dengan nilai epoch terbaik dari pengujian sebelumnya.

Tabel 4 Hasil Pengujian Layer & Neuron

Layer & Neuron	RMSE	MAE	MAPE
[64]	1,1952	0,6476	15,51%
[128]	1,2379	0,6264	15,43%
[64, 64]	1,2282	0,6873	16,50%
[64, 128]	1,2048	0,6752	16,40%
[128, 64]	1,3339	0,6527	16,51%
[128, 128]	1,1986	0,6209	14,74%


Tabel 3 menunjukkan hasil pengujian pada skenario yang menguji jumlah layer dan neuron. Pengujian ini terdiri dari 6 skenario pengujian mulai dari pengujian menggunakan 1 layer dengan neuron senilai 64, hingga pengujian menggunakan 2 layer dan nilai neuron yang keduanya bernilai sebesar 128. Pada pengujian ini, nilai loss yang diperoleh hampir sama rata. Semua nilai RMSE berada di atas 1 dan nilai MAE nya rata-rata berada di angka 0,6.

Pada pengujian ini, nilai terbaik didapat dari pengujian menggunakan 2 layer dan jumlah neuron sebesar 128 dan 128. Nilai RMSE yang didapat dari skenario terakhir ini mencapai 1,1986. Nilai ini sedikit lebih tinggi dari pengujian menggunakan 64 neuron dan 1 layer. Selain itu didapat juga nilai MAE sebesar 0,6209 dan nilai MAPE sebesar 14,74%.



Gbr 2 Grafik Loss Hasil Pengujian Terbaik

Pada Gbr 2 ditunjukkan hasil dari pengujian terbaik yang menggunakan 2 layer dengan masing-masing neuron berjumlah 128. Pada pengujian ini, model tidak mengalami overfitting maupun underfitting. Kurva validation loss dapat mengikuti kurva training walaupun pada awal pelatihan nilai loss sempat mengalami fluktuasi, namun pada akhir pelatihan kurva menunjukkan tren positif.



Gbr 3 Grafik Prediksi Hasil Pengujian Terbaik

Pada Gbr 3 ditunjukkan grafik prediksi hasil pengujian terbaik. Pada grafik tersebut ditunjukkan bahwa hasil prediksi sempat mengalami perbedaan di awal pelatihan. Namun pada sekitar tahun 2022, grafik menunjukkan tren positif dimana kurva prediksi dapat mengikuti kurva aktual. Hal ini terus membaik seiring waktu hingga akhir prediksi.

Berdasarkan hasil pengujian, nilai RMSE terbaik yang didapat selama penelitian adalah sebesar 1,1986. Selain dari penelitian ini, hasil pengujian LSTM ini juga dianggap lebih baik dari beberapa hasil pengujian lain. Dalam penelitian ini penulis juga mencoba mengimplementasikan model Triple Exponential Smoothing (TES) dan ARIMA sebagai model pembandingan.

Tabel 5 Grafik Perbandingan Beberapa Model

Model	RMSE	MAE	MAPE
LSTM	1,1986	0,6209	14,74%
ARIMA	1,9666	1,6838	71,71%
TES	2,5605	1,908	45,22%

Kedua model tersebut merupakan algoritma prediksi model lama. Model-model ini pernah digunakan untuk memprediksi tingkat inflasi di Jawa Barat. Berdasarkan hasil pengujian nilai RMSE dari model TES hanya dapat mencapai 2,5605. Nilai ini

lebih tinggi dibandingkan model LSTM yang diuji sebelumnya. Selain itu, ARIMA sendiri menunjukkan hasil yang lebih baik dari TES yakni sebesar 1,9666 namun nilai tersebut masih lebih tinggi dari model LSTM.

IV. KESIMPULAN

Penelitian ini merupakan sebuah penelitian untuk mencoba mengimplementasikan model LSTM untuk prediksi tingkat inflasi di Jawa Timur. Pengujian ini menggunakan 2 skenario utama, yakni mencari nilai epoch terbaik dan kemudian mencari jumlah layer dan neuron terbaik. Pada pengujian ini nilai epoch terbaik yang didapat adalah model dengan jumlah epoch sebesar 100. Hal ini dibuktikan dengan nilai RMSE sebesar 1,1952. Nilai epoch ini kemudian digunakan sebagai jumlah epoch pada pengujian untuk mencari jumlah layer dan neuron terbaik. Pada pengujian ini jumlah layer terbaik yang didapat adalah model dengan 2 layer dengan masing-masing layer terdiri dari 128 neuron.

Hasil dari pengujian ini tidak menunjukkan adanya overfitting maupun underfitting selama pelatihan. Model lain juga diuji sebagai model pembanding dalam penelitian ini. Model TES misalnya yang hanya mendapat nilai RMSE sebesar 2,5605. Selain itu diuji juga model ARIMA yang hanya mendapat nilai RMSE sebesar 1,9666.

Hasil dari pengujian ini menunjukkan bahwa model LSTM dapat digunakan untuk melakukan prediksi tingkat inflasi di Jawa Timur. Namun meskipun hasil menunjukkan hasil yang cukup baik, penggunaan LSTM masih dapat dijelajahi lebih jauh lagi. Misalnya dengan menguji perbandingan nilai learning rate, timestep, maupun jumlah layer yang lebih dari 2. Selain itu, pengujian ini masih menggunakan data univariat. Penelitian selanjutnya dapat mencoba menggunakan data lain sebagai pendukung penelitian sesuai dengan pengaruh tingkat inflasi di suatu wilayah.

UCAPAN TERIMA KASIH

Penelitian ini dapat terwujud berkat dukungan dari beberapa pihak. Penelitian ini akan digunakan penulis sebagai pendukung dalam Seminar Nasional Informatika Bela Negara. Untuk itu penulis mengucapkan terima kasih kepada teman-teman penulis yang telah memberikan bantuan baik secara moril maupun materi selama penulisan penelitian ini. penulis juga ingin mengucapkan terima kasih kepada berbagai peneliti yang beberapa penelitiannya digunakan sebagai rujukan dalam penelitian ini. Tanpa adanya penelitian-penelitian tersebut, penulis mungkin akan kesulitan dalam menyelesaikan penelitian ini.

REFERENSI

- [1] Kelompok Kerja Nasional TPID, "Buku Petunjuk TPID," Jakarta, Mar. 2014.
- [2] R. E. Jarot, J. Pudjowati, and A. Fattah, "Analisis Faktor-Faktor yang Mempengaruhi Tingkat Inflasi di Jawa Timur," *EkoBis: Jurnal Ekonomi & Bisnis*, vol. 1, no. 2, pp. 98–108, Mar. 2021, doi: 10.46821/ekobis.v1i2.33.
- [3] "Inflasi Tahun ke Tahun (Y o Y) - Tabel Statistik - Badan Pusat Statistik Provinsi Jawa Timur." Accessed: Oct. 28, 2025. [Online]. Available:

<https://jatim.bps.go.id/id/statistics-table/2/NDYjMg==/inflasi-tahun-ke-tahun.html>

- [4] R. T. Ahsan and N. A. K. Rifai, "Perbandingan Metode Seasonal ARIMA dan Metode Fuzzy Time Series-Markov Pada Prediksi Inflasi di Indonesia," *Bandung Conference Series: Statistics*, vol. 3, no. 2, pp. 662–669, Sep. 2023, doi: 10.29313/bcss.v3i2.9138.
- [5] E. Mutiara Nuralifia and Rodiah, "Analisis Perbandingan Metode Terbaik Peramalan Inflasi di Jawa Barat dengan ARIMA, Linear Regression, Triple Exponential Smoothing," *Jurnal Sistem Informasi Bisnis*, p. 1, 2025, doi: 10.21456/vol15iss1pp11-20.
- [6] K. Greff, R. K. Srivastava, J. Koutnik, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A Search Space Odyssey," *IEEE Trans Neural Netw Learn Syst*, vol. 28, no. 10, pp. 2222–2232, Oct. 2017, doi: 10.1109/TNNLS.2016.2582924.
- [7] M. F. Rizkilloh and S. Widiyanesti, "Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 25–31, Feb. 2022, doi: 10.29207/resti.v6i1.3630.
- [8] W. Sumarjaya and M. Susilawati, "Forecasting Monthly Inflation Rate in Denpasar Using Long Short-Term Memory," vol. 13, no. 1, pp. 11–24, 2023, doi: 10.24843/JMAT.2023.v13.i01.p157.
- [9] V. Gallan, "LSTM (Long Short Term Memory).," *Medium*. Accessed: Oct. 31, 2025. [Online]. Available: <https://medium.com/bina-nusantara-it-division/lstm-long-short-term-memory-d29779e2ebf8>