

Perbandingan Model Long Short-Term Memory (LSTM) dan ARIMA untuk Prediksi Inflasi dan Indeks Harga Konsumen (IHK) di Kota Jayapura

Happy Alyzhya Haay^{*1}, Anggrainy Togi Marito Siregar², Dina Jumiatal Fitri³, Rasi Kasim Samosir⁴

^{1,2}Program Studi Matematika, Universitas Cenderawasih, Indonesia

³Program Studi Statistika, Universitas Cenderawasih, Indonesia

⁴Program Studi Planologi, Universitas Cenderawasih, Indonesia

e-mail: happyalzyhya98@gmail.com

Abstrak

Inflasi dan Indeks Harga Konsumen (IHK) merupakan indikator makroekonomi penting yang memerlukan model prediksi yang andal untuk mendukung pengambilan keputusan. Penelitian ini membandingkan kinerja model Long Short-Term Memory (LSTM) dan Autoregressive Integrated Moving Average (ARIMA) dalam memprediksi Inflasi dan IHK menggunakan data deret waktu bulanan. Model LSTM dilatih dengan mekanisme EarlyStopping untuk mencegah overfitting, dan diuji pada empat konfigurasi panjang timesteps (3, 6, 9, dan 12). Hasil terbaik diperoleh pada timesteps = 9, yang kemudian dibandingkan dengan model ARIMA(1,1,1). Evaluasi dengan metrik Mean Squared Error (MSE), Mean Absolute Error (MAE), dan koefisien determinasi (R^2) menunjukkan bahwa untuk variabel Inflasi, kedua model menghasilkan R^2 negatif (LSTM = -0,012; ARIMA = -0,027), yang mengindikasikan kedua model belum mampu mengungguli prediksi nilai rata-rata sederhana. Untuk variabel IHK, LSTM menunjukkan performa lebih baik dibandingkan ARIMA ($R^2 = 0,197$ berbanding -0,002), meskipun kemampuan penjelasan variansnya masih tergolong rendah. Penelitian ini mengonfirmasi bahwa keterbatasan jumlah data historis menjadi kendala utama bagi model deep learning seperti LSTM, sehingga model sederhana seperti ARIMA tetap kompetitif pada kondisi data yang minim.

Kata kunci— Inflasi, IHK, LSTM, ARIMA

1. PENDAHULUAN

Inflasi merupakan salah satu indikator makroekonomi yang menunjukkan kecenderungan kenaikan harga barang dan jasa secara umum dalam suatu periode tertentu. Perubahan tingkat inflasi memiliki dampak yang signifikan terhadap daya beli masyarakat, investasi, serta stabilitas ekonomi suatu daerah. Salah satu indikator yang digunakan untuk mengukur tingkat inflasi adalah Indeks Harga Konsumen (IHK), yaitu indeks yang menggambarkan perubahan harga rata-rata dari sejumlah barang dan jasa yang dikonsumsi rumah tangga. Oleh karena itu, prediksi inflasi dan IHK yang akurat menjadi sangat penting sebagai dasar pengambilan kebijakan ekonomi, pengendalian harga, serta perencanaan pembangunan daerah.

Perkembangan teknologi kecerdasan buatan telah mendorong pemanfaatan berbagai metode prediksi berbasis machine learning pada data deret waktu (time series). Salah satu metode yang banyak digunakan adalah Long Short-Term Memory (LSTM), yang merupakan pengembangan dari Recurrent Neural Network (RNN) dan memiliki kemampuan untuk mempelajari hubungan jangka panjang pada data sekuensial. Selain metode berbasis deep learning, model statistik klasik seperti Autoregressive Integrated Moving Average (ARIMA) masih menjadi pendekatan yang banyak digunakan karena memiliki interpretasi yang baik dan mampu memberikan hasil yang kompetitif, terutama pada data dengan jumlah observasi yang terbatas. Oleh karena itu, perbandingan kedua metode tersebut menjadi penting untuk mengetahui model yang paling sesuai dalam memprediksi indikator ekonomi.

Beberapa penelitian terdahulu telah menunjukkan bahwa model LSTM mampu memberikan performa yang baik pada berbagai permasalahan prediksi data deret waktu. Penelitian tentang penerapan metode LSTM untuk memprediksi harga bahan pokok nasional di Indonesia menggunakan data time series periode 2018–

2021 (Cahyani et al., 2023). Penelitian tersebut menunjukkan bahwa optimizer ADAM menghasilkan performa terbaik pada sebagian besar komoditas dengan akurasi tertinggi mencapai nilai R^2 sebesar 0,8852. Sementara itu, perbandingan metode LSTM dan ARIMA dalam memprediksi jumlah kasus positif Covid-19 di Indonesia dan menemukan bahwa LSTM memiliki tingkat akurasi yang lebih tinggi dibandingkan ARIMA karena lebih mampu menangkap pola data yang bersifat nonlinier dan fluktuatif (Alfason et al., 2023). Penelitian lain juga menunjukkan bahwa LSTM dapat digunakan untuk memprediksi laju inflasi berdasarkan data ekonomi Kota Ternate dengan hasil yang memadai (Masipupu et al., 2025). Selain itu, perbandingan metode LSTM dengan Naïve Bayes pada klasifikasi sentimen ulasan pengguna Shopee dan menemukan bahwa LSTM memiliki nilai precision, recall, dan F1-score yang lebih baik dalam menangkap pola kompleks meskipun akurasi keseluruhannya sedikit lebih rendah (Ifadah & Irawan, 2025).

Berdasarkan penelitian-penelitian tersebut, dapat disimpulkan bahwa LSTM memiliki keunggulan dalam mempelajari pola nonlinier dan hubungan jangka panjang pada berbagai jenis data. Persamaan penelitian-penelitian terdahulu dengan penelitian ini terletak pada penggunaan LSTM sebagai model utama dalam proses prediksi maupun analisis pola data. Namun demikian, terdapat beberapa perbedaan yang mendasar. Sebagian besar penelitian sebelumnya menggunakan objek penelitian berupa harga komoditas, kasus Covid-19, maupun data teks, sedangkan penelitian ini berfokus pada indikator makroekonomi daerah berupa inflasi dan IHK Kota Jayapura. Selain itu, penelitian terdahulu umumnya dilakukan pada jumlah data yang relatif lebih besar atau pada karakteristik data yang sangat fluktuatif, sehingga performa LSTM dapat berkembang secara optimal. Di sisi lain, penelitian yang membandingkan LSTM dengan ARIMA pada data ekonomi daerah yang memiliki jumlah observasi terbatas masih relatif sedikit. Keterbatasan tersebut menyebabkan belum adanya pemahaman yang memadai mengenai efektivitas kedua model pada kondisi data historis yang minim.

Berdasarkan hasil sintesis penelitian terdahulu, masih terdapat beberapa research gap yang perlu dikaji lebih lanjut. Pertama, sebagian besar penelitian lebih menitikberatkan pada peningkatan akurasi model tanpa mengevaluasi pengaruh konfigurasi timesteps terhadap stabilitas performa LSTM ketika jumlah data relatif sedikit. Kedua, penelitian yang secara langsung membandingkan LSTM dan ARIMA dalam memprediksi dua indikator makroekonomi daerah, yaitu inflasi dan Indeks Harga Konsumen (IHK), menggunakan data bulanan dengan jumlah observasi terbatas masih sangat terbatas. Padahal, karakteristik data ekonomi regional berbeda dengan data finansial atau data berfrekuensi tinggi karena umumnya hanya tersedia dalam periode bulanan sehingga berpotensi memengaruhi kemampuan generalisasi model deep learning.

Berdasarkan research gap tersebut, novelty penelitian ini terletak pada analisis komparatif antara model LSTM dan ARIMA untuk memprediksi inflasi dan IHK Kota Jayapura menggunakan data historis bulanan yang terbatas, disertai evaluasi empat konfigurasi timesteps (3, 6, 9, dan 12) untuk mengidentifikasi konfigurasi yang paling optimal pada kondisi data berukuran kecil. Dengan demikian, penelitian ini tidak hanya membandingkan tingkat akurasi kedua model, tetapi juga memberikan pemahaman mengenai sensitivitas performa LSTM terhadap panjang sequence pada data ekonomi daerah yang memiliki jumlah observasi terbatas.

Selama beberapa tahun terakhir, pendekatan pembelajaran mesin, khususnya jaringan saraf tiruan berbasis Long Short-Term Memory (LSTM), banyak digunakan untuk pemodelan data deret waktu ekonomi karena kemampuannya menangkap pola nonlinier dan dependensi jangka panjang. Meskipun demikian, performa model deep learning seperti LSTM sangat bergantung pada ketersediaan data dalam jumlah besar. Pada kasus data ekonomi domestik yang umumnya hanya tersedia dalam frekuensi bulanan dengan rentang waktu terbatas, penerapan LSTM berpotensi mengalami overfitting sehingga tidak selalu menghasilkan performa yang lebih baik dibandingkan model statistik sederhana seperti ARIMA.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja model Long Short-Term Memory (LSTM) dan Autoregressive Integrated Moving Average (ARIMA) dalam memprediksi Inflasi dan Indeks Harga Konsumen (IHK) Kota Jayapura menggunakan data deret waktu bulanan. Selain itu, penelitian ini juga menganalisis pengaruh variasi timesteps terhadap performa model LSTM sehingga dapat diperoleh konfigurasi yang paling sesuai pada kondisi jumlah data historis yang terbatas.

2. METODE PENELITIAN

2.1 Pra-pemrosesan Data

Data yang digunakan dalam penelitian ini terdiri dari dua variabel utama, yaitu data Inflasi bulanan dan Indeks Harga Konsumen (IHK) Kota Jayapura. Kedua variabel digunakan sebagai input sekaligus target prediksi dalam model multivariat LSTM. Data diperoleh dari website Badan Pusat Statistik (BPS) Kota Jayapura yang mencakup periode Januari 2020 hingga Desember 2025, sehingga diperoleh sebanyak 72 observasi bulanan untuk masing-masing variabel. Berdasarkan hasil pemeriksaan data, seluruh data tersedia secara lengkap sehingga proses pemodelan dilakukan menggunakan seluruh observasi yang tersedia.

Untuk memastikan kesesuaian pemodelan deret waktu, dilakukan uji stasioneritas Augmented Dickey-Fuller (ADF) terhadap masing-masing variabel. Data kemudian dinormalisasi menggunakan MinMaxScaler untuk kebutuhan pelatihan model LSTM agar seluruh variabel berada pada rentang nilai yang sama. Sementara itu, data pada skala asli (*unscaled*) tetap disimpan untuk pemodelan ARIMA. Setelah proses prediksi selesai, hasil keluaran model LSTM dikembalikan ke skala data semula (*inverse transform*) menggunakan parameter normalisasi yang sama sehingga nilai evaluasi MSE, MAE, dan R^2 dihitung berdasarkan nilai aktual pada skala aslinya. Tahapan tersebut dilakukan agar hasil prediksi dapat dibandingkan secara langsung dengan model ARIMA yang menggunakan data pada skala asli.

2.2 Model LSTM

LSTM merupakan pengembangan dari RNN yang dilengkapi dengan *memory cell* berupa *cell state* serta tiga gerbang (*forget gate*, *input gate*, dan *output gate*), sehingga mampu mempelajari dependensi jangka panjang pada data sekuensial. *Forget gate* berfungsi menentukan informasi lama yang perlu dipertahankan atau dibuang menggunakan fungsi sigmoid. *Input gate* menentukan informasi baru yang perlu ditambahkan ke dalam *cell state* melalui kombinasi fungsi sigmoid dan tanh. Sementara itu, *output gate* menentukan bagian dari *cell state* yang akan dikeluarkan sebagai *hidden state* untuk digunakan pada langkah berikutnya. Melalui mekanisme ketiga gerbang tersebut, LSTM mampu menyimpan dan memperbarui informasi secara selektif sepanjang urutan data (Masipupu et al., 2025). Secara lengkap LSTM dihitung menggunakan Persamaan (1)–(8).

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

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

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

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

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

$$h_t = \tanh(c_t) * o_t, \quad (6)$$

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

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

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 memory cell* pada waktu t ,

c_t = *state ari memory cell* saat ini pada waktu t

h_t = nilai keluar yang telah difilter output gate

σ = rentang nilai antara 0 dan 1,

$\tanh(x)$ = rentang nilai antara -1 dan 1

Sisi knan persamaan didefinisikan sebagai berikut:

$W_i, W_f, W_o, W_c, H_i, H_f, H_o$, dan H_c merupakan matriks pembobotan

b_i, b_f, b_o , dan b_c adalah vektor bias.

Model LSTM dibangun menggunakan satu lapisan LSTM dengan 16 unit, diikuti lapisan Dropout sebesar 0,1 sebagai regularisasi, dan lapisan Dense dengan aktivasi linear sebagai keluaran akhir untuk dua variabel (Inflasi dan IHK). Model dioptimasi menggunakan Adam dengan learning rate 0,001 dan fungsi kerugian Mean Squared Error (MSE). Konfigurasi tersebut digunakan sebagai parameter pelatihan model dalam penelitian ini untuk memperoleh proses pembelajaran yang stabil pada data deret waktu yang digunakan.

Data dibentuk menjadi *sequence* menggunakan teknik sliding window dengan empat variasi panjang timesteps, yaitu 3, 6, 9, dan 12. Variasi tersebut digunakan untuk mengevaluasi pengaruh panjang urutan data terhadap kemampuan model dalam melakukan prediksi. Pembagian data latih dan data uji dilakukan dengan proporsi 80:20. Proses pelatihan dilakukan maksimal 150 epoch dengan batch size 8, serta menerapkan callback EarlyStopping (*monitor = val_loss, patience = 15, restore_best_weights = True*) untuk menghentikan pelatihan secara otomatis ketika nilai validasi tidak lagi mengalami perbaikan sehingga dapat mengurangi risiko overfitting.

2.3 Model ARIMA

Autoregressive Integrated Moving Average (ARIMA) merupakan metode peramalan yang dikembangkan oleh Box dan Jenkins sehingga sering disebut sebagai metode Box-Jenkins. Metode ini merupakan perpaduan komponen Autoregressive (AR), Integrated (I), dan Moving Average (MA) yang memanfaatkan nilai historis suatu variabel untuk menghasilkan prediksi deret waktu. Berbeda dengan LSTM, model ARIMA tidak menggunakan variabel eksternal, melainkan hanya memanfaatkan hubungan antarobservasi pada data historis (Sinaga, 2023).

Pada penelitian ini, model pembandingan yang digunakan adalah ARIMA(1,1,1). Sebelum proses pemodelan dilakukan uji stasioneritas menggunakan Augmented Dickey-Fuller (ADF), sedangkan proses differencing dilakukan untuk memenuhi asumsi stasioneritas pada variabel yang belum stasioner.

2.4 Evaluasi Kinerja Model

Model yang diperoleh berdasarkan pelatihan menggunakan LSTM, dievaluasi menggunakan MSE (*Mean Square Error*), MAE (*Mean Absolute Error*), dan R^2 (R^2 Score).

- a. *Mean Squared Error* (MSE) merupakan nilai rata-rata dari selisih kuadrat antara hasil prediksi (y_{pred}) dengan nilai sebenarnya (y_{true}). Secara matematis, MSE dapat dirumuskan sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

dengan

$\hat{y}_i$ = hasil peramalan

y_i = nilai actual

n = ukuran sampel

- b. *Mean Absolute Error* (MAE) adalah rata-rata nilai aktual dan nilai prediksi yang bernilai mutlak positif (Ihzaniah et al., 2023). Rumus MAE dapat dilihat pada persamaan 10.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

dengan,

$\hat{y}_i$ = hasil peramalan

y_i = nilai actual

n = ukuran sampel

- c. R^2 (R^2 Score) yang juga dikenal sebagai koefisien determinasi, digunakan untuk mengukur seberapa besar hubungan antara variabel bebas dan variabel tak bebas secara bersama-sama (simultan). Nilai R-Squared berada pada rentang 0 hingga 1 (Cahyani et al., 2023). Rumus perhitungannya dapat dilihat pada persamaan (11) berikut.

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

3. HASIL DAN PEMBAHASAN

3.1 Uji Stasioneritas

Hasil uji Augmented Dickey-Fuller (ADF) menunjukkan bahwa variabel Inflasi bersifat stasioner ($p\text{-value} = 0,0000 < 0,05$), sedangkan variabel IHK tidak stasioner ($p\text{-value} = 0,3519 > 0,05$). Perbedaan karakteristik ini menjadi salah satu pertimbangan penting dalam interpretasi hasil, khususnya untuk model ARIMA yang mengasumsikan proses differencing untuk mencapai stasioneritas.


Karakteristik tersebut dapat dijelaskan berdasarkan sifat masing-masing variabel. Data inflasi merupakan perubahan harga yang dihitung secara periodik sehingga nilainya cenderung berfluktuasi di sekitar rata-rata tertentu tanpa menunjukkan kecenderungan tren jangka panjang yang kuat. Kondisi tersebut menyebabkan variabel inflasi memenuhi asumsi stasioneritas. Sebaliknya, IHK merupakan indeks kumulatif yang menggambarkan perkembangan tingkat harga dari waktu ke waktu. Nilai IHK secara umum terus mengalami peningkatan sebagai akibat perubahan harga yang bersifat akumulatif, sehingga membentuk pola tren dan menyebabkan data belum memenuhi asumsi stasioner. Oleh karena itu, pada pemodelan ARIMA diperlukan proses differencing untuk menghilangkan pengaruh tren sebelum proses estimasi model dilakukan.

3.2 Perbandingan Konfigurasi Timesteps pada Model LSTM

Tabel 1 menyajikan hasil pengujian LSTM pada empat konfigurasi *timesteps*. Konfigurasi *timesteps* = 9 memberikan hasil terbaik untuk kedua variabel, dengan R^2 Inflasi sebesar $-0,012$ dan R^2 IHK sebesar $0,197$. Konfigurasi *timesteps* = 6 dan 12 menunjukkan performa yang jauh lebih rendah, ditandai dengan nilai R^2 yang sangat negatif sehingga mengindikasikan ketidakstabilan model akibat jumlah data latih yang relatif terbatas.

Tabel 1. Perbandingan kinerja model LSTM pada berbagai konfigurasi timesteps

Timesteps	Epoch Berhenti	n_train	n_test	MSE Inflasi	MAE Inflasi	R^2 Inflasi	MSE IHK	MAE IHK	R^2 IHK
3	101	55	14	0,914	0,777	-0,135	0,812	0,767	-0,244
6	15	52	14	11,270	3,236	-13,002	2,003	1,227	-2,069
9	57	50	13	0,772	0,713	-0,012	0,564	0,660	0,197
12	15	48	12	7,649	2,614	-8,287	11,537	3,270	-14,157



Gambar 1. Nilai aktual vs. prediksi LSTM (timesteps = 9) untuk Inflasi dan IHK

Perbedaan performa tersebut menunjukkan bahwa panjang *sequence* yang digunakan berpengaruh terhadap kemampuan model dalam mempelajari pola historis data. Pada *timesteps* = 3, informasi historis yang digunakan relatif pendek sehingga hubungan temporal jangka menengah belum dapat dipelajari secara optimal. Sebaliknya, penggunaan *timesteps* = 12 menyebabkan jumlah sampel pelatihan berkurang karena setiap pembentukan *sequence* memerlukan data historis yang lebih panjang. Akibatnya, model memiliki data latih yang lebih sedikit sehingga proses pembelajaran menjadi kurang stabil. Konfigurasi *timesteps* = 9 memberikan

keseimbangan antara panjang informasi historis yang dipelajari dan jumlah sampel pelatihan yang masih tersedia, sehingga menghasilkan performa terbaik dibandingkan konfigurasi lainnya pada data penelitian ini.


Temuan ini juga menunjukkan bahwa pemilihan *timesteps* tidak dapat dilakukan secara arbitrer, tetapi perlu disesuaikan dengan karakteristik data dan jumlah observasi yang tersedia. Pada data deret waktu dengan jumlah observasi terbatas, penggunaan *timesteps* yang terlalu panjang justru dapat menurunkan kemampuan generalisasi model.

3.3 Perbandingan LSTM dan ARIMA

Tabel 2 menunjukkan bahwa untuk variabel Inflasi, kedua model menghasilkan nilai R^2 negatif (LSTM = $-0,012$; ARIMA = $-0,027$), yang berarti keduanya belum mampu menghasilkan prediksi yang lebih baik dibandingkan prediksi menggunakan nilai rata-rata historis. Meskipun LSTM memperoleh nilai MSE dan MAE yang sedikit lebih rendah dibandingkan ARIMA, perbedaannya relatif kecil sehingga secara praktis kedua model menunjukkan performa yang hampir setara pada variabel inflasi.

Tabel 2. Perbandingan kinerja LSTM dan ARIMA berdasarkan MSE, MAE, dan R^2

Variabel	Model	MSE	MAE	R^2
Inflasi	LSTM (timesteps=9)	0,772	0,713	-0,012
Inflasi	ARIMA(1,1,1)	0,782	0,730	-0,027
IHK	LSTM (timesteps=9)	0,564	0,660	0,197
IHK	ARIMA(1,1,1)	0,704	0,715	-0,002



Gambar 2. Perbandingan nilai aktual, prediksi LSTM, dan prediksi ARIMA untuk Inflasi dan IHK

Untuk variabel IHK, LSTM menunjukkan performa yang lebih baik dibandingkan ARIMA dengan nilai R^2 sebesar 0,197, sedangkan ARIMA menghasilkan nilai $-0,002$. Hasil tersebut menunjukkan bahwa LSTM lebih mampu menangkap pola nonlinier pada data IHK dibandingkan model ARIMA yang mengasumsikan hubungan linier antarobservasi. Meskipun demikian, nilai R^2 yang masih relatif rendah menunjukkan bahwa kemampuan model dalam menjelaskan variasi data belum optimal. Hal tersebut mengindikasikan bahwa jumlah observasi yang terbatas masih menjadi salah satu kendala utama dalam membangun model prediksi berbasis deep learning.

Hasil penelitian ini sejalan dengan penelitian Alfason et al. (2023) yang menunjukkan bahwa LSTM memiliki kemampuan lebih baik dibandingkan ARIMA dalam mempelajari pola data yang bersifat kompleks dan nonlinier (Alfason et al., 2023). Persamaan kedua penelitian terletak pada keunggulan LSTM dalam menghasilkan performa prediksi yang lebih baik dibandingkan ARIMA. Namun demikian, besarnya peningkatan performa pada penelitian ini tidak sebesar yang dilaporkan oleh Alfason et al. Perbedaan tersebut diduga dipengaruhi oleh karakteristik data yang digunakan. Penelitian Alfason et al. menggunakan data harian kasus Covid-19 dengan jumlah observasi yang jauh lebih besar dan pola fluktuasi yang lebih kompleks, sedangkan penelitian ini menggunakan data inflasi dan IHK bulanan dengan hanya 72 observasi sehingga informasi yang tersedia untuk proses pelatihan model relatif terbatas.

Temuan penelitian ini juga memiliki kesamaan dengan penelitian Cahyani, Mujahidin, dan Palyus (2023) yang menunjukkan bahwa LSTM mampu memberikan hasil prediksi yang baik apabila konfigurasi model ditentukan secara tepat (Cahyani et al., 2023). Pada penelitian ini, pengaruh konfigurasi tersebut terlihat dari variasi nilai *timesteps* yang menghasilkan performa berbeda-beda. Hal ini menunjukkan bahwa keberhasilan model LSTM tidak hanya dipengaruhi oleh algoritma yang digunakan, tetapi juga oleh pemilihan parameter pelatihan dan karakteristik data yang dimodelkan.

Di sisi lain, hasil penelitian ini berbeda dengan penelitian (Wadiyan et al., n.d.) yang melaporkan bahwa LSTM jauh lebih unggul dibandingkan ARIMA pada prediksi harga cryptocurrency Solana. Perbedaan tersebut kemungkinan disebabkan oleh perbedaan karakteristik data. Data cryptocurrency memiliki jumlah observasi yang jauh lebih besar, frekuensi harian, serta pola nonlinier yang kuat sehingga lebih sesuai untuk dimodelkan menggunakan deep learning. Sebaliknya, data inflasi dan IHK Kota Jayapura memiliki jumlah observasi yang relatif sedikit sehingga kemampuan LSTM untuk mempelajari pola kompleks menjadi terbatas. Akibatnya, pada variabel inflasi performa LSTM dan ARIMA menjadi relatif setara, sedangkan keunggulan LSTM hanya terlihat pada variabel IHK.

Secara keseluruhan, hasil penelitian ini memperlihatkan bahwa efektivitas model prediksi tidak hanya dipengaruhi oleh kompleksitas algoritma, tetapi juga sangat bergantung pada karakteristik data, jumlah observasi, dan konfigurasi model yang digunakan. Oleh karena itu, pada data deret waktu dengan jumlah observasi yang terbatas, model statistik seperti ARIMA masih dapat menjadi alternatif yang kompetitif, sedangkan LSTM menunjukkan keunggulan ketika pola data yang dipelajari memiliki karakteristik nonlinier yang lebih kuat.

4. KESIMPULAN

Penelitian ini membandingkan kinerja model Long Short-Term Memory (LSTM) dan Autoregressive Integrated Moving Average (ARIMA) dalam memprediksi Inflasi dan Indeks Harga Konsumen (IHK) Kota Jayapura. Hasil penelitian menunjukkan bahwa konfigurasi *timesteps* = 9 memberikan performa LSTM terbaik. Pada variabel Inflasi, LSTM dan ARIMA menunjukkan performa yang relatif setara, sedangkan pada variabel IHK, LSTM menghasilkan performa yang lebih baik dibandingkan ARIMA meskipun nilai R^2 yang diperoleh masih tergolong rendah.

Penelitian ini memberikan kontribusi dalam menunjukkan bahwa efektivitas LSTM pada data ekonomi daerah sangat dipengaruhi oleh jumlah data historis dan pemilihan *timesteps*, sehingga model statistik seperti ARIMA masih menjadi alternatif yang kompetitif pada data yang terbatas. Keterbatasan penelitian ini terletak pada jumlah observasi yang relatif sedikit dan perbandingan yang hanya dilakukan dengan model ARIMA. Oleh karena itu, penelitian selanjutnya disarankan menggunakan data yang lebih panjang serta mengeksplorasi model atau pendekatan hibrida untuk meningkatkan akurasi prediksi.

DAFTAR PUSTAKA

- Alfason, B., Diana, S., Agung, A., Gunawan, S., Alfason, B., Diana, S., Agung, A., & Gunawan, S. (2023). ScienceDirect ScienceDirect Forecasting of Covid-19 positive cases in Indonesia using long Forecasting of Covid-19 positive cases in Indonesia using long memory (LSTM) short-term memory (LSTM). *Procedia Computer Science*, 216(2022), 177–185. <https://doi.org/10.1016/j.procs.2022.12.125>
- Cahyani, J., Mujahidin, S., & Palyus, T. (2023). *Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional*. 11(2), 346–357. <https://doi.org/10.26418/justin.v11i2.57395>
- Ifadah, M., & Irawan, B. (2025). Analisis Kinerja Metode Long Short-Term Memory (LSTM) dalam Klasifikasi Sentimen Ulasan Pengguna Shopee. *Jurnal Elektronika Dan Komputer*, 18(2), 405–414.
- Ihzaniah, L. S., Setiawan, A., Wijaya, R. W. N., Matematika, P. S., Kristen, U., Wacana, S., Tengah, J., & Berganda, R. L. (2023). *JAMBURA JOURNAL OF PROBABILITY AND STATISTICS Volume 4 Nomor 1, Mei 2023*. 4, 17–29.
- Masipupu, F. A., Setiawan, A., & Susanto, B. (2025). *Prediksi Laju Inflasi dengan Metode Long Short-Term*

Memory (LSTM) Berdasarkan Data Laju Inflasi dan Pengeluaran Kota Ternate Prediksi Laju Inflasi dengan Metode Long Short-Term Memory (LSTM) Berdasarkan Data Laju Inflasi dan Pengeluaran Kota Ternate. 6(1), 28–34.

Sinaga, S. A. (2023). *Implementasi Metode Arima (Autoregressive Moving Average) Untuk Prediksi Penjualan Mobil. 2(3), 102–109.*

Wadiyan, Permata, Priandika, A. T., & Gunawan, R. D. (n.d.). *Building of Informatics, Technology and Science (BITS) Journal.*