

PENERAPAN MODEL HIBRIDA ARIMA-LSTM PADA PREDIKSI INFLASI DI INDONESIA

Divanda Shaffa Ameera, Aviolla Terza Damaliana, Mohammad Idhom

Sains Data, Universitas Pembangunan Nasional Veteran Jawa Timur

Jalan Raya Rungkut Madya, Gunung Anyar, Surabaya, Indonesia

ameeradivanda@gmail.com

ABSTRAK

Pengendalian inflasi penting untuk menjaga stabilitas ekonomi dan kesejahteraan masyarakat. Oleh karena itu, diperlukan perencanaan dan pengelolaan inflasi yang baik sebagai kunci untuk menjaga stabilitas ekonomi dan memastikan pertumbuhan yang berkelanjutan. Prediksi inflasi yang tepat memungkinkan pemerintah dan pelaku ekonomi untuk merancang kebijakan dan strategi yang efektif dalam menjaga stabilitas ekonomi. Penelitian ini bertujuan untuk menerapkan model hibrida ARIMA-LSTM untuk memprediksi inflasi di Indonesia. Konsep model hibrida yang sudah lama digunakan dalam literatur *time series* memungkinkan peneliti untuk memanfaatkan kelebihan dari setiap model dan memprediksi data dengan lebih efektif. Model ARIMA-LSTM adalah model hibrida yang menggabungkan dua metode peramalan, yaitu ARIMA (*AutoRegressive Integrated Moving Average*) dan LSTM (*Long Short-Term Memory*). Model ARIMA diterapkan pada komponen tren, sedangkan model LSTM diterapkan pada komponen musiman dan residual. Penelitian ini menggunakan data inflasi Indonesia sejak 1979 hingga 2024. Nilai terbaik yang didapatkan adalah kombinasi ARIMA (1, 1, 1) dengan LSTM yang menggunakan arsitektur sederhana, dengan satu lapisan LSTM yang terdiri dari 50 unit dan fungsi aktivasi ReLU. Dari hasil penggabungan ARIMA dan LSTM, didapatkan hasil evaluasi MAE = 0.27, MSE = 0.14, dan RMSE = 0.37. Hasil ini menunjukkan bahwa model memiliki performa yang baik.

Kata kunci : inflasi, prediksi, ARIMA, LSTM, hibrida

1. PENDAHULUAN

Perekonomian Indonesia saat ini menunjukkan ketahanan meskipun dihadapkan pada ketidakpastian global yang meningkat. Inflasi memainkan peran krusial dalam stabilitas serta pertumbuhan ekonomi, menjadikannya salah satu faktor utama yang perlu diperhatikan. Inflasi merupakan kenaikan harga barang dan jasa secara umum dan berkelanjutan dalam jangka waktu tertentu. Jika hanya terjadi kenaikan harga pada satu atau dua jenis barang tanpa memicu peningkatan harga secara luas, maka kondisi tersebut tidak dikategorikan sebagai inflasi. Sebaliknya, deflasi merupakan kebalikan dari inflasi [1].

Di Indonesia, Badan Pusat Statistik (BPS) mengukur inflasi dengan menggunakan Indeks Harga Konsumen (IHK). Inflasi terbagi menjadi dua jenis, yaitu inflasi inti yang cenderung stabil serta inflasi non-inti yang lebih fluktuatif karena dipengaruhi oleh harga pangan dan kebijakan pemerintah. Faktor penyebab inflasi meliputi tekanan dari sisi penawaran, permintaan, serta ekspektasi masyarakat.

Pengendalian inflasi menjadi aspek penting dalam menjaga stabilitas ekonomi dan kesejahteraan masyarakat. Menjaga inflasi dalam batas yang terkendali diperlukan guna mendukung pertumbuhan ekonomi yang berkelanjutan dan mencegah dampak negatif terhadap kesejahteraan masyarakat. Dampak inflasi sangat bergantung pada tingkatannya. Inflasi yang tinggi dapat mengurangi daya beli masyarakat akibat melemahnya nilai mata uang, sehingga jumlah barang dan jasa yang dapat dibeli dengan uang yang sama menjadi lebih sedikit. Secara makroekonomi,

inflasi yang lebih tinggi dibandingkan dengan negara lain dapat menurunkan daya saing produk ekspor, menjadikannya lebih mahal di pasar internasional, sementara impor menjadi lebih murah, yang berpotensi merugikan neraca perdagangan [2].

Sebaliknya, inflasi yang terlalu rendah atau deflasi dapat memperlambat pertumbuhan ekonomi, karena masyarakat dan pelaku usaha cenderung menunda konsumsi dan investasi dengan harapan harga akan terus menurun. Oleh karena itu, pengelolaan inflasi yang efektif menjadi kunci dalam menjaga stabilitas ekonomi dan memastikan pertumbuhan yang berkelanjutan. Prediksi inflasi yang tepat memungkinkan pemerintah dan pelaku ekonomi untuk merancang kebijakan dan strategi yang efektif dalam menjaga stabilitas harga dan mencegah tekanan ekonomi lebih lanjut.

Sebagai upaya untuk meningkatkan akurasi dan kinerja model, penggabungan algoritma dalam bidang *machine learning* semakin populer, baik dengan teknik statistik maupun dengan teknik *machine learning* lainnya. Pendekatan ini memungkinkan model untuk saling melengkapi, mengatasi kelemahan masing-masing, dan menghasilkan prediksi yang lebih andal.

Konsep penggabungan atau model hibrida sudah lama digunakan dalam literatur *time series*. Pendekatan ini memungkinkan peneliti untuk memanfaatkan kelebihan dari setiap model dan memprediksi data dengan lebih efektif. Model ARIMA-LSTM adalah model hibrida yang menggabungkan dua metode peramalan, yaitu ARIMA (*AutoRegressive Integrated Moving Average*)

dan LSTM (*Long Short-Term Memory*). Model ARIMA diterapkan pada komponen tren, sedangkan model LSTM diterapkan pada komponen musiman dan residual [3].

Terdapat beberapa penelitian serupa yang telah dilakukan sebelumnya. Pada penelitian yang dilakukan oleh Emmanuel Dave, dkk [4].

Penelitian ini mengevaluasi kinerja Model hibrida (LSTM-ARIMA) dan model tunggal LSTM dan ARIMA guna memprediksi ekspor Indonesia satu tahun ke depan. Model LSTM-ARIMA mencapai metrik kesalahan terendah di antara semua model yang diuji. Model ini berhasil mengungguli model-model tunggal lainnya, dengan nilai MAPE sebesar 7,38% dan RMSE sebesar $1,66 \times 10^{13}$. Kemudian, penelitian yang dilakukan Sana, dkk [5].

Penelitian ini akan memodelkan data PDB dan menguji tiga metode, yaitu LSTM, ARIMA, dan selanjutnya model hibrida antara keduanya. Penelitian ini menunjukkan bahwa model hibrida ARIMA-LSTM mencapai akurasi prediksi yang lebih baik daripada model individual dalam memprediksi PDB. Diperoleh hasil akhir yaitu LSTM (RMSE=0.104, MAE=0.077, MSE=0.010, R²=0.96), ARIMA (RMSE=0.309, MAE=0.286, MSE=0.095, R²=0.75), dan hibrida (RMSE=0.043, MAE=0.028, MSE=0.0018, R²=0.99).

Penelitian ini bertujuan untuk menerapkan model hibrida ARIMA LSTM untuk memprediksi inflasi di Indonesia yang dapat mendukung perencanaan serta pengelolaan ekonomi yang lebih efektif. Diharapkan penelitian ini dapat memberikan wawasan lebih lanjut mengenai model prediksi inflasi yang sesuai untuk Indonesia.

2. TINJAUAN PUSTAKA

Tinjauan pustaka memuat teori dan konsep yang relevan dengan topik yang akan diteliti sebagai dasar untuk melanjutkan pada tahap penelitian berikutnya. Berikut adalah beberapa teori yang relevan dengan penelitian.

2.1. Inflasi

Inflasi adalah peningkatan harga barang dan jasa secara umum yang terjadi secara berkelanjutan dalam periode waktu tertentu. Peningkatan harga yang terjadi pada periode tertentu bukan termasuk inflasi. Milton, sebagaimana dikutip oleh Mankiw, menyatakan bahwa inflasi adalah fenomena moneter yang terjadi akibat pertumbuhan jumlah uang yang beredar secara berlebihan [6].

Inflasi dapat diklasifikasikan menjadi dua jenis utama berdasarkan penyebabnya, yaitu *Demand Pull Inflation* dan *Cost Push Inflation*. *Demand Pull Inflation* terjadi ketika permintaan agregat dalam suatu ekonomi tumbuh lebih cepat daripada kemampuan produksi. Hal ini sering kali disebabkan oleh peningkatan konsumsi, dimana konsumen memiliki lebih banyak uang untuk dibelanjakan, baik karena peningkatan pendapatan, kebijakan moneter yang

longgar, atau kebijakan fiskal yang ekspansif. Selain itu, peningkatan investasi oleh dunia usaha, peningkatan pengeluaran pemerintah, atau peningkatan ekspor juga dapat menyebabkan inflasi tersebut. Ketika permintaan terhadap suatu barang atau jasa meningkat dan pasokan tidak meningkat, harga naik dan terjadi inflasi.

Sebaliknya, *Cost Push Inflation* terjadi ketika biaya produksi suatu barang atau jasa meningkat, sehingga mendorong produsen menaikkan harga untuk mempertahankan margin keuntungan. Penyebab utama inflasi ini antara lain kenaikan harga bahan baku, kenaikan upah tanpa meningkatkan produktivitas, devaluasi mata uang yang meningkatkan harga barang impor, dan kebijakan pemerintah yang meningkatkan biaya produksi. Peningkatan biaya produksi ini cenderung mengurangi pasokan perekonomian secara keseluruhan, sehingga mengakibatkan harga barang dan jasa menjadi lebih tinggi dan menyebabkan inflasi [2].

Perbedaan utama kedua jenis inflasi ini terletak pada pemicunya. *Demand Pull Inflation* bergantung pada peningkatan permintaan dalam perekonomian, sedangkan *Cost Push Inflation* melibatkan peningkatan biaya produksi. Kedua hal ini dapat terjadi bersamaan dan menyebabkan peningkatan tekanan inflasi terhadap perekonomian.

2.2. ARIMA

Metode *Autoregressive Integrated Moving Average* (ARIMA), yang juga dikenal sebagai metode Box Jenkins, diperkenalkan oleh Gwilym Jenkins dan George Box pada tahun 1970. Teknik ini digunakan untuk melakukan prediksi dengan menyintesis pola dari data historis. Model ARIMA adalah gabungan dari model AR (*autoregressive*) dan model MA (*moving average*). Model AR digunakan untuk memprediksi pergerakan suatu variabel berdasarkan nilai dari variabel itu sendiri pada periode sebelumnya, sedangkan model MA memanfaatkan residual dari periode sebelumnya untuk prediksi [7].


Jika dibandingkan dengan berbagai metode peramalan lainnya seperti GARCH, VAR, dan CAPM, yang memiliki karakteristik berbeda, ARIMA dianggap sebagai metode yang paling sesuai untuk data runtun waktu (*time series*). Bentuk umum model *Autoregressive Integrated Moving Average* (ARIMA) ditunjukkan pada persamaan berikut:

$$Z_t = b_0 + b_1 Z_{t-1} + \dots + b_p Z_{t-p} + e_t - c_1 e_{t-1} - \dots - c_q e_{t-q} \quad (1)$$

Dalam persamaan 1, Z_t merepresentasikan nilai data pada waktu t , sedangkan b_0 adalah konstanta dalam model. Komponen *autoregressive* (AR) diwakili oleh koefisien $b_1, b_2, \dots, b_p$, yang menunjukkan hubungan antara nilai saat ini dengan beberapa nilai sebelumnya, yaitu $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$. Selain itu, model ini juga memiliki komponen *moving average* (MA), yang ditunjukkan oleh koefisien $c_1, c_2, \dots, c_q$ yang menangkap efek dari kesalahan

sebelumnya dalam model, yaitu $e_{t-1}, e_{t-2}, \dots, e_{t-q}$ dengan e_t sebagai error (*white noise*) pada waktu t .

Metode ARIMA dirancang untuk digunakan pada data yang bersifat stasioner, artinya bahwa rata-rata dan varians data yang bersifat konstan [8]. Namun, pada kenyataannya, banyak data *time series* yang bersifat non-stasioner. Jika data yang digunakan tidak stasioner, maka diperlukan langkah *differencing* dan transformasi. Tahapan ARIMA dapat dilihat pada gambar 1.




Gambar 1. Tahapan ARIMA

Secara umum, model ARIMA dinyatakan dengan $ARIMA(p, d, q)$ yang menunjukkan model ARIMA dengan derajat AR (p), derajat pembeda yaitu d atau differencing, dan derajat MA (q). Hasil ARIMA akan tepat digunakan untuk jangka pendek, sedangkan dalam jangka panjang akan konstan.

2.3. LSTM

LSTM (*Long Short-Term Memory*) adalah jenis jaringan saraf tiruan berbasis RNN (*Recurrent Neural Network*) yang dirancang untuk menangani data berurutan dengan ketergantungan jangka panjang [9]. LSTM mampu mengatasi masalah vanishing gradient, yang sering terjadi pada RNN standar, sehingga lebih efektif dalam menangani prediksi deret waktu seperti inflasi, harga saham, dan teks [10].



Gambar 2. Arsitektur LSTM

Perhitungan dalam LSTM mencakup penerapan bobot dan bias pada persamaan khusus di setiap gate, sehingga model dapat mengolah serta mempertahankan informasi dengan lebih efisien [11].

Setiap unit LSTM menerima *input* pada waktu tertentu, yang dikenal sebagai X_t , dan menggabungkannya dengan *output* dari unit sebelumnya, yaitu h_{t-1} . Proses pertama yang terjadi adalah melalui *forget gate*, di mana LSTM memutuskan informasi mana dari memori sebelumnya C_{t-1} yang harus dilupakan atau dipertahankan.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2)$$

Pada persamaan kedua, f_t adalah nilai antara 0 dan 1 yang menunjukkan seberapa besar informasi sebelumnya C_{t-1} harus dilupakan. Dimana nilai 1 berarti informasi akan sepenuhnya dipertahankan, dan 0 berarti informasi tersebut akan diabaikan. *Forget* ini melakukan perhitungan dengan cell state. Selanjutnya, *input gate* bertugas menentukan informasi baru yang akan disimpan dalam sel memori.

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

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (3)$$

Kemudian ada perhitungan *Input Gate* pada persamaan tiga, berasal dari kombinasi antara X_t dan h_{t-1} yang diproses melalui dua fungsi aktivasi sigmoid dan tanh. Fungsi sigmoid digunakan untuk menghasilkan i_t , yang menentukan seberapa besar informasi baru akan disimpan, sedangkan fungsi tanh menghasilkan kandidat memori baru $\tilde{C}_t$. Setelah itu, memori sel diperbarui dengan menggabungkan informasi yang dipertahankan oleh *forget gate* dan informasi baru yang diterima melalui *input gate*.

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t) \quad (4)$$

Langkah terakhir adalah *output gate* pada persamaan empat. Disini, o_t mengontrol seberapa banyak informasi dari sel memori yang akan diteruskan sebagai output h_t . *Output* ini juga dipengaruhi oleh X_t dan h_{t-1} , serta modifikasi yang dilakukan pada memori sel oleh fungsi tanh pada persamaan terakhir [12].

Dengan menggunakan mekanisme tiga gerbang ini, LSTM dapat mengingat informasi jangka panjang dan membuang informasi yang tidak relevan, sehingga sangat efektif untuk pemodelan data sekuensial seperti deret waktu, pemrosesan bahasa alami, dan prediksi berbasis historis.

2.4. Evaluasi Kinerja Model

Dalam mengevaluasi kinerja model prediksi, penggunaan skor evaluasi yang tepat sangat penting untuk menentukan akurasi dan efektivitas model. Beberapa evaluasi umum yang digunakan meliputi *Mean Square Error* (MSE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Error* (MAE). Skor evaluasi ini memberikan gambaran tentang seberapa baik model mampu memprediksi nilai yang sebenarnya, serta membantu mengidentifikasi model mana yang lebih unggul dalam menghasilkan prediksi yang andal. Melalui analisis evaluasi ini, kita dapat mengukur sejauh mana model dapat meminimalkan kesalahan dan memberikan prakiraan yang akurat.

Mean Absolute Error atau MAE merupakan salah satu skor evaluasi yang sering digunakan. Skor MAE diukur sebagai rata-rata dari nilai kesalahan absolut. Absolut artinya bilangan akan bernilai positif. Rumus 4 adalah rumus MAE.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (4)$$

Mean Square Error atau MSE menggambarkan seberapa jauh nilai prediksi dari nilai aktual dengan cara mengkuadratkan setiap selisih, sehingga memberikan penalti yang lebih besar untuk kesalahan besar. Rumus 5 adalah rumus MSE.

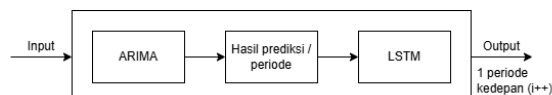
$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

Root Mean Square Error (RMSE) mengukur rata-rata besar kesalahan antara nilai prediksi dan nilai aktual, memberikan satu angka yang dapat digunakan untuk menilai akurasi model. RMSE memberikan bobot lebih besar pada kesalahan besar karena mengkuadratkan kesalahan sebelum dirata-rata. Rumus RMSE adalah seperti pada rumus 6.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

3. METODE PENELITIAN

Penelitian ini dilakukan dengan dengan memadukan metode ARIMA dan LSTM. Model ARIMA diterapkan pada komponen tren, sedangkan model LSTM diterapkan pada komponen musiman dan residual. Secara garis besar, sistem prediksi ARIMA-LSTM ditunjukkan pada gambar 3.



Gambar 3. Tahapan model hibrida

Proses dimulai dengan memasukkan data input, yang berupa data *time series* yang akan diprediksi. Pada penelitian ini yaitu tingkat inflasi. Selanjutnya, model ARIMA digunakan untuk membuat prediksi awal dengan menangkap pola linear dalam data. ARIMA menghasilkan hasil prediksi per periode, yaitu komponen yang diprediksi berdasarkan pola historis. Pada tahap ini, residual atau kesalahan prediksi yang dihasilkan oleh ARIMA, yang tidak dapat dijelaskan oleh pola linear, akan diteruskan ke model LSTM (*Long Short-Term Memory*). LSTM berfungsi untuk menangani pola *non-linear* dalam data yang tidak dapat ditangani oleh ARIMA.

Setelah itu, LSTM memproses data residual ARIMA. Sebelum membangun model dilakukan pemisahan data (*splitting* data) menjadi data pelatihan (*training*) dan pengujian (*testing*), serta dilakukan proses *scaling* data. LSTM sensitif terhadap skala data karena menggunakan fungsi aktivasi seperti sigmoid atau tanh, yang bekerja optimal pada rentang nilai tertentu. Kemudian membangun model. Model ini kemudian dilatih menggunakan data *training* yang telah diproses sebelumnya. Setelah model LSTM dilatih, dilakukan prediksi menggunakan LSTM.

Setelah model LSTM diuji, selanjutnya akan dihasilkan output akhir, yaitu prediksi yang sudah menggabungkan prediksi linear dari ARIMA dan prediksi *non-linear* dari LSTM. Output ini memberikan prediksi untuk satu periode ke depan ($i++$).

Selanjutnya dilakukan evaluasi model, di mana kinerja model hibrida dinilai menggunakan skor evaluasi, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE). Setelah evaluasi dilakukan dan mendapat model yang sudah di training, prediksi untuk 2025 bisa dilakukan.

Tahap akhir yaitu menganalisis hasil penelitian untuk mendapatkan kesimpulan terkait performa model dalam memprediksi inflasi di Indonesia.

4. HASIL DAN PEMBAHASAN

Penelitian ini dilakukan dengan dengan memadukan metode ARIMA dan LSTM menggunakan data inflasi Indonesia sejak tahun 1979 hingga 2024.

4.1. Tahapan ARIMA


Pada tahapan awal ini, dilakukan penyesuaian dataset inflasi yang awalnya dalam format berbasis tahun menjadi format *time series* bulanan yang ditunjukkan pada gambar 4. Data inilah yang diinput dan digunakan dalam pemodelan.

Tingkat Inflasi	
1979-01-01	2.58
1979-02-01	2.34
1979-03-01	0.55
1979-04-01	3.02
1979-05-01	3.05
...	...
2024-08-01	-0.03
2024-09-01	-0.12
2024-10-01	0.08
2024-11-01	0.30
2024-12-01	0.44


[552 rows x 1 columns]

Gambar 4. Dataset

Sebelum melakukan analisis lebih lanjut terhadap data deret waktu, langkah pertama yang penting adalah memahami pola dan karakteristik data secara visual. *Time series* plot pada gambar 5 berperan sebagai alat utama dalam eksplorasi ini, karena memungkinkan kita untuk melihat bagaimana suatu variabel berubah seiring waktu. Dengan sumbu X mewakili waktu dan sumbu Y menunjukkan nilai variabel yang diamati, plot ini memberikan gambaran awal mengenai tren, musiman, atau fluktuasi lain yang mungkin ada dalam data.

Gambar 5. Grafik *time series* inflasi

Gambar 5 menunjukkan menunjukkan plot deret waktu tingkat inflasi per tahun dari 1979 hingga Desember 2024. Data menunjukkan adanya fluktuasi yang cukup signifikan dalam tingkat inflasi, dengan lonjakan tinggi sekitar tahun 1998, yang mungkin terkait dengan krisis ekonomi pada periode tersebut. Setelah itu dilakukan pengujian asumsi ARIMA, yaitu uji stasioneritas untuk menentukan apakah data perlu dilakukan transformasi agar memenuhi asumsi model. Dari uji tersebut, hasil uji kpss menunjukkan bahwa $p - value = 0.02$ Karena $p - value \leq 0.05$ maka dilakukan *differencing* satu kali. Setelah itu kita uji kembali dan hasil uji kpss menunjukkan $p - value = 0.1$ artinya data sudah stasioner dan memiliki *unit root*. Plot ACF dan PACF yang sudah stasioner dapat dilihat pada gambar 6.




Gambar 6. Plot ACF&PACF

Plot ACF pada gambar 6 memperlihatkan bahwa lag 1 memiliki nilai tinggi, lalu cepat turun dan fluktuatif di sekitar nol dan tidak ada cutoff yang jelas setelah lag tertentu, tetapi peluruhan terjadi dengan cepat. Sehingga $q = 1$ atau 0. Untuk PACF terputus tajam di lag 1 dan setelahnya nilai mendekati nol. Ini menunjukkan kemungkinan model ARIMA dengan $p=1$. Model yang kemungkinan digunakan adalah ARIMA (1, 1, 0) atau ARIMA (1, 1, 1). Untuk melihat mana yang lebih optimal adalah dengan

membandingkan nilai AIC/BIC. Didapatkan nilai AIC: 1620.31 dan BIC: 1633.24 untuk ARIMA (1, 1, 0), dan AIC: 1517.98, BIC: 1535.23 untuk ARIMA (1, 1, 1). Sehingga dalam kasus ini digunakan ARIMA (1, 1, 1).

Selanjutnya adalah pembagian data training dan data testing. Data training berisi seluruh data kecuali 12 data terakhir. Sedangkan data testing berisi 12 data terakhir. Setelah itu membangun model ARIMA, didapatkan nilai residual dari ARIMA. Kemudian dilakukan analisis terhadap residual (selisih antara prediksi model dan nilai aktual).



Gambar 7. Plot ACF&PACF residual

Residual dari model ARIMA seharusnya bersifat white noise. Jika dilihat pada gambar 7 hampir semua lag berada dalam batas kepercayaan yang menunjukkan bahwa residual tidak memiliki pola tertentu dan bersifat acak. Namun, perlu dilakukan uji Ljung-Box untuk mengonfirmasi residual benar-benar white noise. Hasil uji menunjukkan $lb_stat = 34.829564$ dan $lb_pvalue = 0.000134$. Karena $p - value \leq 0.05$, artinya residual bersifat white noise. Oleh karena itu, residual dari model ARIMA ini akan digunakan sebagai input untuk model LSTM.

4.2. Tahapan LSTM

Sebelum membuat model LSTM, diperlukan beberapa langkah pre-processing data untuk memastikan model bekerja dengan optimal. Pertama, normalisasi data karena LSTM sensitif terhadap skala data. Jika rentang nilai terlalu besar, gradien yang diperbarui selama backpropagation dapat menjadi tidak stabil. Sehingga dilakukan normalisasi dengan Min-Max Scaling untuk memetakan data ke dalam rentang $[-1, 1]$.


Kemudian, membentuk data sekuensial (*windowing*). LSTM membutuhkan input dalam bentuk sekuensial (*timesteps*). Pada penelitian ini $timesteps = 5$. Penentuan *timesteps* ini

mempertimbangkan dimensi data dan pendekatan grid secara manual.

Proses selanjutnya adalah pembagian data. Penelitian ini membagi data training sebanyak 80% dan data testing sebanyak 20%. Langkah selanjutnya adalah *me-reshape* data untuk LSTM. LSTM membutuhkan input dengan bentuk (*samples, timesteps, features*). Model *Long Short-Term Memory* (LSTM) yang digunakan dalam penelitian ini menggunakan arsitektur sederhana dengan satu lapisan LSTM yang terdiri dari 50 unit dan fungsi aktivasi ReLU (*Rectified Linear Unit*). Lapisan LSTM ini menerima input dalam bentuk sekuensial, dengan bentuk (*timesteps, 1*) yang mencerminkan jumlah langkah waktu yang digunakan sebagai fitur dalam setiap observasi. Setelah lapisan LSTM, model memiliki satu lapisan keluaran Dense dengan satu *neuron* untuk menghasilkan prediksi nilai inflasi.


Untuk optimasi, model dikompilasi menggunakan algoritma Adam (*Adaptive Moment Estimation*) dengan learning rate sebesar 0.001, yang dikenal efektif dalam menangani data *time series* dan mempercepat konvergensi. Model ini menggunakan fungsi loss *Mean Squared Error* (MSE) sebagai skor evaluasi selama proses pelatihan untuk meminimalkan selisih antara nilai aktual dan prediksi. Model dilatih menggunakan 50 *epoch* dengan ukuran *batch* 16, yang bertujuan untuk menyesuaikan bobot jaringan secara bertahap dengan lebih stabil. Pemilihan parameter ini dilakukan berdasarkan uji coba iteratif serta evaluasi performa menggunakan data validasi untuk memastikan model dapat memprediksi inflasi dengan akurasi yang baik.

Setelah itu, model LSTM diuji, dan langkah berikutnya adalah menggabungkan hasil prediksi linear dari ARIMA dengan prediksi non-linear dari LSTM.



Gambar 8. Visualisasi nilai aktual vs prediksi data training

Visualisasi pada gambar 8 menunjukkan perbandingan antara data aktual (ditampilkan dalam warna biru) dan hasil prediksi model hibrida ARIMA-LSTM (ditampilkan dalam warna merah) pada data train. Secara keseluruhan, visualisasi ini menunjukkan bahwa model hibrida ARIMA-LSTM bekerja dengan baik dalam memprediksi data train, meskipun masih ada beberapa perbedaan yang dapat diperbaiki untuk meningkatkan akurasi.



Gambar 9. Visualisasi nilai aktual vs prediksi data testing

Visualisasi pada gambar 9 menunjukkan perbandingan antara data aktual inflasi dengan hasil prediksi model hibrida ARIMA-LSTM pada data *testing*. Dari visualisasi ini, terlihat bahwa model hibrida ARIMA-LSTM mampu menangkap pola pergerakan data latih dengan cukup baik. Model berhasil mengikuti fluktuasi data aktual, termasuk lonjakan nilai inflasi yang terjadi pada beberapa titik waktu tertentu. Namun, terdapat beberapa deviasi antara prediksi dan data aktual, terutama pada titik-titik dengan perubahan yang sangat tajam.

Untuk menilai seberapa baik model hibrida ARIMA-LSTM dalam melakukan prediksi, dilakukan penilaian menggunakan skor evaluasi. Tabel 1 adalah hasil evaluasi kinerja model hibrida ARIMA-LSTM

Tabel 1. Hasil evaluasi model hibrida

Model	MAE	MSE	RMSE
ARIMA-LSTM	0.27	0.14	0.37

Hasil evaluasi ini menunjukkan bahwa model hibrida ARIMA-LSTM berhasil menangkap pola data dengan baik dan prediksinya dapat dianggap cukup baik.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian menggunakan model hibrida ARIMA-LSTM yang diterapkan pada data inflasi Indonesia, ditemukan bahwa model memiliki performa yang baik. Hasil prediksi inflasi Indonesia selama 10 periode selanjutnya yaitu [0.37, 0.30, 0.30, 0.24, 0.22, 0.18, 0.17, 0.15, 0.15, 0.14]. Berdasarkan hasil prediksi model hibrida ARIMA-LSTM, inflasi Indonesia dalam 10 periode ke depan cenderung mengalami stabilisasi dengan penurunan yang semakin kecil di bulan-bulan terakhir. Secara keseluruhan, hasil prediksi ini mengindikasikan bahwa inflasi dalam beberapa bulan ke depan berpotensi mengalami penurunan yang cukup stabil. Namun, analisis lebih lanjut diperlukan untuk memahami faktor-faktor makroekonomi yang dapat mempengaruhi realisasi inflasi di masa mendatang. Untuk penelitian selanjutnya, dapat mempertimbangkan arsitektur RNN lain (seperti GRU atau varian LSTM) untuk membandingkan kinerja model.

DAFTAR PUSTAKA

- [1] Bank Indonesia, "Inflasi." Accessed: Feb. 11, 2025. [Online]. Available: <https://www.bi.go.id/id/fungsi-utama/moneter/inflasi/default.aspx>
- [2] V. D. SS and F. Fadli, "Mendalami Korelasi Pasar Saham, Inflasi, dan Nilai Tukar," p. 184, 2024, Accessed: Feb. 11, 2025. [Online]. Available: https://play.google.com/store/books/details/Mendalami_Korelasi_Pasar_Saham_Inflasi_dan_Nilai_T?id=LPjvEAAAQBAJ&hl=id
- [3] S. Ray, A. Lama, P. Mishra, T. Biswas, S. Sankar Das, and B. Gurung, "An ARIMA-LSTM model for predicting volatile agricultural price series with random forest technique," *Appl. Soft Comput.*, vol. 149, p. 110939, Dec. 2023, doi: 10.1016/J.ASOC.2023.110939.
- [4] E. Dave, A. Leonardo, M. Jeanice, and N. Hanafiah, "Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM," *Procedia Comput. Sci.*, vol. 179, pp. 480–487, Jan. 2021, doi: 10.1016/J.PROCS.2021.01.031.
- [5] S. Hamiane, Y. Ghanou, H. Khalifi, and M. Telmem, "Comparative Analysis of LSTM, ARIMA, and Hybrid Models for Forecasting Future GDP," *Ing. des Syst. d'Information*, vol. 29, no. 3, pp. 853–861, Jun. 2024, doi: 10.18280/ISI.290306.
- [6] N. G. Mankiw, R. D. Kneebone, and K. J. McKenzie, "Principles of macroeconomics," p. 448, 2024, Accessed: Feb. 11, 2025. [Online]. Available: https://books.google.com/books/about/Principles_of_Macroeconomics_9th_Edition.html?hl=id&id=Hm22EAAAQBAJ
- [7] D. Wahyuni, R. A. Lusua, Z. Zeleansi, D. Deti, and ..., "Aplikasi Model Arima Dalam Memprediksi Jumlah Kasus Penyebaran Covid-19 Di Provinsi Kepulauan Bangka Belitung," *Proc. ...*, pp. 112–117, 2021, [Online]. Available: <https://journal.ubb.ac.id/index.php/snppm/article/download/2717/1589>
- [8] N. F. Khusna, S. Aulia, S. Amaria, A. Rahmah, S. A. Sanmas, and F. Fauzi, "Peramalan Kualitas Udara di Semarang Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA) Forecasting Air Quality in Semarang Using the Autoregressive Integrated Moving Average (ARIMA) Method," *Pros. Semin. Nas. UNIMUS*, pp. 426–435, 2023.
- [9] R. Al Kiramy, I. Permana, and A. Marsal, "Comparison of RNN and LSTM Algorithm Performance in Predicting the Number of Umrah Pilgrims at PT . Hajar Aswad Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT . Hajar Aswad," vol. 4, no. October, pp. 1224–1234, 2024.
- [10] Roni Merdiansah, Khofifah Wulandari, Mentari Hasibuan, and Yuyun Umaidah, "Perbandingan Kinerja Model RNN, LSTM, dan BLSTM dalam Memprediksi Jumlah Gempa Bulanan di Indonesia," *J. Penelit. Rumpun Ilmu Tek.*, vol. 3, no. 1, pp. 262–277, 2024, doi: 10.55606/juprit.v3i1.3466.
- [11] J. Cahyani, S. Mujahidin, and T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," *J. Sist. dan Teknol. Inf.*, vol. 11, no. 2, p. 346, 2023, doi: 10.26418/justin.v11i2.57395.
- [12] R. Luthfiansyah and B. Wasito, "Penerapan Teknik Deep Learning (Long Short Term Memory) dan Pendekatan Klasik (Regresi Linier) dalam Prediksi Pergerakan Saham BRI," *J. Inform. dan Bisnis*, vol. 12, no. 2, pp. 42–54, 2023, doi: 10.46806/jib.v12i2.1059.