

Inflation Prediction in Indonesia Using Extreme Learning Machine and K-Fold Cross Validation

Wahda Aulia Assara, Zamahsary Martha*, Dony Permana, Dina Fitria

Departemen Statistika, Universitas Negeri Padang, Kota Padang, Indonesia

*Corresponding author: zamahsarymartha@fmipa.unp.ac.id

Submitted : 29 Juli 2025
Revised : 20 Agustus 2025
Accepted : 21 Agustus 2025

ABSTRACT

Inflation rate forecasting is an important aspect in supporting economic policies and price control by the government. This study aims to evaluate the performance of the Extreme Learning Machine (ELM) algorithm in forecasting the inflation rate in Indonesia and provide inflation prediction results for 2025. The data used is historical data on Indonesia's inflation rate for the period 2003–2024. The analysis process begins with data normalization to ensure a uniform scale, followed by data partitioning using 10-Fold Cross Validation. The ELM model was built with 30 hidden neurons, a sigmoid activation function, and a regularization parameter of 0.8. The test results show that the ELM algorithm has superior performance. This is evidenced by the average MAPE value of 1.71%, RMSE of 0.0359, and coefficient of determination (R^2) of 0.9833, indicating very high accuracy. The inflation prediction for January to December 2025 is in the range of 1.517%–1.761%, with an average approaching 1.663%, indicating a relatively stable pattern throughout the year. Based on these results, the ELM algorithm can be used as an effective alternative method for forecasting time series data, particularly in the context of inflation. This research is expected to serve as a reference for the government in establishing inflation control policies and for other researchers interested in applying artificial intelligence models to economic analysis.

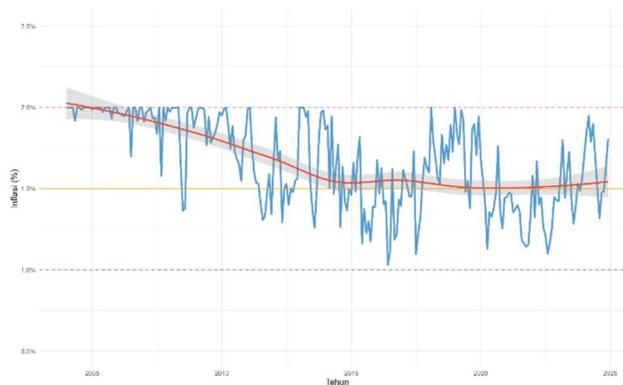
Keywords: *Extreme Learning Machine, Forecasting, Inflation, K-Fold Cross Validation, Time Series.*



This is an open access article under the Creative Commons 4.0 Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. ©2022 by author and Universitas Negeri Padang.

I. PENDAHULUAN

Inflasi di Indonesia mengalami fluktuasi dari tahun ke tahun. Hal ini berarti tingkat inflasi di Indonesia berubah-ubah dari waktu ke waktu, baik naik maupun turun dalam periode yang relatif singkat. Kondisi ini menyebabkan tingkat harga barang dan jasa dapat naik atau turun secara tidak terduga yang dapat mempengaruhi daya beli konsumen, keuntungan perusahaan, dan kondisi ekonomi secara keseluruhan. Oleh karena itu, kondisi ini menjadi tantangan bagi pemerintah dalam merumuskan kebijakan moneter dan fiskal Indonesia, sehingga diperlukan pendekatan yang mampu memprediksi inflasi secara akurat. Fluktuasi inflasi yang terjadi di Indonesia dapat menimbulkan ketidakpastian ekonomi dan memerlukan pendekatan prediktif yang tepat dalam pengambilan keputusan makroekonomi (Wahyuni dkk, 2020).



Gambar 1. Grafik Inflasi Indonesia Jan 2003 - Des2024

Berdasarkan Gambar 1, dapat disimpulkan bahwa beberapa dekade terakhir dalam kurun waktu 2003-2024 grafik inflasi Indonesia mengalami fluktuatif (berubah-ubah) baik naik maupun turun dengan persentase pertumbuhan inflasi yang beragam. Data ini diambil langsung dari website resmi Bank Indonesia (www.bi.go.id) tentang inflasi bulanan Indonesia periode Januari 2003-Desember 2024. Grafik sepanjang 2020 relatif rendah, dan fluktuasi dari tahun 2016 lebih terkendali dibanding tahun-tahun sebelumnya. Persentase kenaikan inflasi tertinggi terjadi pada Desember 2005 dengan nilai 18%, dan persentase terendah tercatat pada Agustus 2020 dengan nilai 1,32%. Fluktuasi ini mencerminkan pengaruh dinamika ekonomi domestik dan global. Oleh karena itu, pengelolaan inflasi memerlukan perencanaan ekonomi yang tepat serta kebijakan moneter dan fiskal yang efektif.

Inflasi yang stabil penting untuk menjaga daya beli masyarakat, mendorong kepastian usaha, dan memperkuat kestabilan ekonomi. Dalam rangka mendukung pengambilan kebijakan yang tepat, diperlukan metode prediksi inflasi yang andal dan akurat. Informasi prediktif ini bermanfaat bagi berbagai pihak, termasuk investor, pelaku usaha, dan petani. Menurut Sari dkk (2017), prediksi harga yang tepat dapat meningkatkan efisiensi distribusi, terutama di sektor pertanian, serta membantu perencanaan ekonomi secara lebih optimal.

Salah satu metode prediksi yang dinilai efektif adalah *Extreme Learning Machine* (ELM), yaitu algoritma jaringan saraf tiruan tipe *feedforward* dengan pelatihan satu tahap. ELM pertama kali diperkenalkan oleh Huang dkk. (2004) sebagai pendekatan pembelajaran yang lebih cepat dibandingkan metode *backpropagation* konvensional. Ciri khas utama ELM adalah bobot input dan bias yang diinisialisasi secara acak dan tidak diperbarui selama pelatihan, sehingga bobot output dapat dihitung langsung menggunakan metode *pseudo-inverse* (Huang dkk, 2006). ELM terbukti mampu menangani data yang kompleks dan *nonlinier* dengan efisiensi komputasi yang tinggi (Gopakumar dkk, 2015). Penelitian terbaru juga menunjukkan bahwa ELM efektif digunakan untuk peramalan data ekonomi yang fluktuatif, termasuk inflasi, karena kemampuannya dalam generalisasi cepat dan akurasi tinggi (Widodo dkk, 2021; Pramadia dkk, 2024; Goldani, 2024).

Dalam penelitian ini, proses validasi model dilakukan dengan menggunakan metode *K-Fold Cross Validation*. Teknik ini membagi data menjadi K bagian (*fold*), lalu secara bergantian menggunakan satu *fold* sebagai data uji dan sisanya sebagai data latih. Proses ini diulang sebanyak K kali sehingga setiap data memiliki peluang yang sama untuk menjadi data uji. James dkk. (2013) menyatakan bahwa *K-Fold Cross Validation* merupakan metode validasi yang efektif dalam mengevaluasi performa model secara menyeluruh serta mengurangi kemungkinan terjadinya *overfitting*. Selain itu, teknik ini membantu dalam memilih model yang memiliki tingkat akurasi dan kemampuan generalisasi terbaik untuk memprediksi data baru, termasuk dalam konteks prediksi inflasi di Indonesia. Temuan terkini juga menegaskan bahwa *K-Fold* sangat relevan untuk meningkatkan akurasi model pembelajaran mesin dalam konteks prediksi deret waktu maupun data ekonomi (Khan dkk, 2022; Wulandari dkk, 2023; Pramadia dkk, 2024). Dengan demikian, kombinasi ELM dan *K-Fold Cross Validation* diharapkan mampu menghasilkan model prediksi inflasi yang lebih akurat dan andal.

II. METODE PENELITIAN

A. Sumber Data dan Jenis Penelitian

Penelitian ini menggunakan data sekunder yang diambil langsung dari situs Bank Indonesia tentang inflasi Indonesia periode Januari 2003 – Desember 2024. Jenis penelitian yang digunakan adalah penelitian kuantitatif dengan pendekatan prediktif dan komputasional yang bertujuan untuk meramalkan tingkat inflasi di Indonesia menggunakan metode *Extreme Learning Machine* (ELM). Penelitian ini memanfaatkan data historis inflasi sebagai input untuk membangun model prediksi, dengan proses pelatihan dan pengujian dilakukan secara sistematis menggunakan teknik *K-Fold Cross Validation*.

B. Teknik Analisis Data

Teknik analisis data yang digunakan yaitu *Extreme Learning Machine* dengan *K-Fold Cross Validation* dan menggunakan *software R Studio*. Adapun langkah-langkahnya sebagai berikut.

1. Mengumpulkan data angka inflasi Indonesia dari situs Bank Indonesia periode Januari 2003 – Desember 2024 sebanyak 264 data.
2. Melakukan proses normalisasi data yang bertujuan untuk mengubah skala data inflasi ke dalam rentang antara 0 dan 1, guna mempercepat proses pelatihan dan menghindari dominasi fitur-fitur dengan nilai besar. Normalisasi juga membantu meningkatkan stabilitas numerik model dan performa umum selama pelatihan. Untuk proses normalisasi data digunakan Persamaan (1) dimana v adalah data asli dan max adalah data maksimal dari dataset.

$$v' = \frac{v}{max} \quad (1)$$

3. Melakukan pembagian data menggunakan metode *K-Fold Cross Validation*. Teknik ini membagi dataset menjadi k bagian (*fold*), lalu model dilatih k kali dengan menggunakan $k-1$ *fold* sebagai data latih dan 1 *fold* sebagai data uji secara bergantian. Disini peneliti menggunakan 10 *fold*, karena jumlah ini mampu memberikan keseimbangan antara kestabilan hasil evaluasi dan efisiensi komputasi. Proses pembagian data dilakukan secara acak agar distribusi data tetap merata di setiap *fold*, sesuai karakteristik data yang sudah menggunakan fitur prediktor. Pendekatan ini mampu mengurangi risiko *overfitting* dan memberikan evaluasi performa model yang lebih menyeluruh.
4. Membangun model ELM. Model ini merupakan jenis jaringan saraf dengan pelatihan sangat cepat karena bobot antara lapisan *input* dan *hidden* diinisialisasi secara acak dan tidak diperbarui selama proses pelatihan. Dalam proses ini, ditentukan jumlah *neuron* pada lapisan tersembunyi, kemudian dipilih fungsi aktivasi *sigmoid*, serta dilakukan inisialisasi bobot acak. Hasil aktivasi dari *hidden layer* digunakan untuk menghitung bobot *output* secara matematis menggunakan metode *pseudo-inverse* atau regularisasi *linear*.
Langkah 1. Melakukan inisialisasi bobot secara acak untuk membentuk matriks bobot *input* W . Nilai bobot ini diambil dari distribusi seragam dalam rentang $(-1,1)$. Bobot ini akan digunakan untuk memproyeksikan data *input* ke *hidden layer*.
Langkah 2. Melakukan perhitungan matriks keluaran awal dari *hidden layer* yang dilambangkan dengan H_{init} , menggunakan Persamaan (2)

$$H_{init} = X.W^T \quad (2)$$

- Langkah 3. Menghitung aktivasi *hidden layer* menggunakan fungsi aktivasi *sigmoid* terhadap H_{init} . Hasil aktivasi ini dilambangkan dengan H , yang dihitung dengan Persamaan (3)

$$H = \frac{1}{1 + e^{-H_{init}}} \quad (3)$$

- Langkah 4. Menghitung *Moore-Penrose Pseudo-Inverse* dari matriks H , yang dilambangkan dengan H^+ . *Pseudo-inverse* diperlukan untuk memperoleh bobot *output* tanpa proses iteratif, dapat dilakukan dengan Persamaan (4).

$$H^+ = H^T (H^T H)^{-1} \quad (4)$$

- Langkah 5. Menghitung bobot *output* akhir β , yaitu bobot dari *hidden layer* ke *output layer*, dengan menggunakan Persamaan (5).

$$\beta = H^+ T \quad (5)$$

5. Melakukan perhitungan untuk proses *testing*. Langkah-langkah proses *testing* (Giusti dkk, 2018) sebagai berikut.
Langkah 1. Menginisialisasi bobot yang telah terbentuk pada proses *training*.
Langkah 2. Hasil keluaran di *hidden layer* dihitung dengan fungsi aktivasi *sigmoid*.
Langkah 3. Menghitung hasil keluaran *output layer* atau Y menggunakan persamaan (6).

$$Y = H.\beta \quad (6)$$

6. Setelah model dibangun dan dilatih, evaluasi performa dilakukan menggunakan metrik seperti *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Metrik-metrik ini memberikan gambaran akurasi model dalam memprediksi nilai inflasi, dan yang digunakan untuk menentukan parameter terbaik yang menghasilkan RMSE, MAE dan MAPE terkecil. Semakin kecil nilai RMSE, MAE dan MAPE maka semakin baik akurasi model dalam melakukan prediksi.
Menurut Azmi et al. (2020), rumus RMSE sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (7)$$

- Menurut Suryanto & Muqtadir (2019), rumus MAE sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (8)$$

- Menurut Najar et al (2018), rumus MAPE sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - P_i}{P_i} \right| \times 100\% \quad (9)$$

- Langkah terakhir adalah denormalisasi data. Hasil prediksi yang sebelumnya dalam skala normalisasi dikembalikan ke skala aslinya agar dapat diinterpretasikan secara nyata dalam konteks ekonomi. Selain itu, seluruh hasil evaluasi kemudian disusun dalam bentuk dashboard interaktif untuk memberikan gambaran menyeluruh tentang kinerja model, stabilitas, kesalahan prediksi, serta potensi penerapannya dalam pengambilan keputusan ekonomi. Untuk menghitung denormalisasi digunakan Persamaan (10):

$$v = v' \times \max \quad (10)$$

III. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk mengevaluasi kinerja algoritma *Extreme Learning Machine* (ELM) dalam meramalkan laju inflasi di Indonesia, serta menentukan model yang paling akurat untuk melakukan prediksi inflasi pada periode Januari–Desember 2025. ELM termasuk dalam kategori jaringan saraf tiruan (*Artificial Neural Network*), ELM dikenal dengan kecepatan pelatihan yang tinggi dan kemampuan generalisasi yang baik. Hasil penelitian ini menunjukkan bahwa algoritma ELM memberikan tingkat akurasi yang tinggi dalam meramalkan laju inflasi Indonesia.

A. Analisis *Extreme Learning Machine* (ELM)

Dalam proses peramalan inflasi menggunakan ELM, pemilihan fitur atau prediktor yang relevan sangat berperan penting terhadap performa model. Prediktor digunakan sebagai input dalam model pembelajaran mesin, dan dalam konteks peramalan deret waktu (*time series*), fitur-fitur ini dapat mencakup nilai-nilai historis dari variabel target (inflasi), serta fitur-fitur musiman dan temporal lainnya. Berdasarkan preprocessing yang dilakukan, diperoleh sebanyak 27 prediktor yang nantinya akan dijadikan layer input pada model. Beberapa variabel prediktor utama yang digunakan mencakup data inflasi lag (Inflation_Lag1, Lag2, Lag3, Lag6, Lag12), serta indikator statistik bergerak seperti *moving average* (MA_3, MA_6, MA_12) dan *exponential moving average* (EMA_3, EMA_6).

Fungsi aktivasi yang digunakan pada lapisan tersembunyi adalah *sigmoid*, yang sesuai dengan karakteristik data inflasi yang memiliki rentang kecil dan memerlukan *output* yang halus. *Sigmoid* mampu mengubah input menjadi nilai antara 0 dan 1, sehingga cocok dengan data yang sudah dinormalisasi. Dalam penelitian ini, struktur model ELM (*Extreme Learning Machine*) dirancang berdasarkan jumlah *input layer*, *hidden layer* dan *output layer*.

Jumlah *neuron* pada *input layer* ditentukan sebanyak 26, yang berasal dari 27 prediktor yang digunakan, dikurangi satu karena dalam proses pelatihan ELM, variabel target tidak dihitung sebagai input. Sementara itu, jumlah *neuron* pada *hidden layer* ditetapkan sebanyak 30, yang diperoleh melalui serangkaian uji coba dan tuning model dengan mempertimbangkan performa metrik evaluasi terkecil pada validasi silang (*K-Fold Cross Validation*).

Selanjutnya, jumlah *neuron* pada *output layer* adalah 1 karena model hanya meramalkan satu nilai inflasi untuk setiap bulan pada periode target. Adapun nilai regulasi yang digunakan adalah sebesar 0.8, yang ditentukan dari proses eksperimental dengan mencoba beberapa nilai untuk mengontrol kompleksitas model dan mencegah *overfitting*. Koefisien regulasi ini berfungsi sebagai penalti terhadap bobot besar dalam jaringan untuk menyeimbangkan bias dan varians, sehingga membantu meningkatkan generalisasi model terhadap data baru. Pemilihan parameter ini secara keseluruhan diarahkan untuk menghasilkan model ELM terbaik yang mampu memprediksi laju inflasi secara akurat berdasarkan pola historis dan faktor musiman.

B. Analisis Prediksi



Gambar 2. Prediksi Inflasi Bulanan di Indonesia Periode Jan 2025 – Des 2025

Gambar 2 menunjukkan hasil peramalan inflasi oleh model ELM yang sebagian besar titik prediksi terkonsentrasi dekat garis diagonal merah, yang mewakili kondisi ideal di mana nilai prediksi tepat sesuai target. Kerapatan hasil di sekitar garis ini menandakan tingkat akurasi tinggi, memperlihatkan bahwa model mampu menangkap pola data historis dengan baik. Sehingga secara keseluruhan model menunjukkan performa prediksi yang kuat dan andal.

Tabel 1. Hasil Peramalan Inflasi Bulanan di Indonesia Periode Januari 2025 – Desember 2025

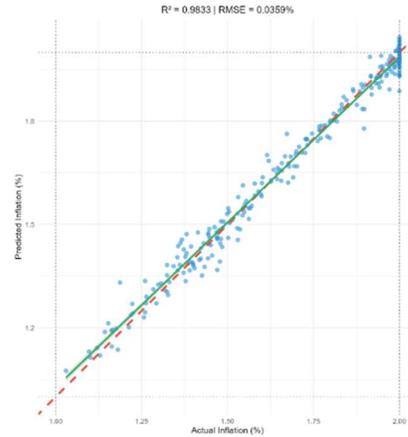
Periode	Hasil Peramalan
Januari 2025	1,752 %
Februari 2025	1,688 %
Maret 2025	1,705 %
April 2025	1,761 %
Mei 2025	1,659 %
Juni 2025	1,630 %
Juli 2025	1,755 %
Agustus 2025	1,630 %
September 2025	1,685 %
Oktober 2025	1, 517 %
November 2025	1,545 %
Desember 2025	1,629 %

Dari Tabel 1, dapat dilihat bahwa hasil peramalan inflasi bulanan di Indonesia selama periode Januari hingga Desember 2025 berada dalam kisaran 1,517% hingga 1,761%. Nilai inflasi tertinggi diperkirakan terjadi pada April 2025 sebesar 1,761%, diikuti oleh Januari 1,752% dan Juli 1,755%, yang menunjukkan potensi tekanan harga yang relatif tinggi di awal dan pertengahan tahun.

Sementara itu, inflasi terendah diproyeksikan terjadi pada Oktober 2025 sebesar 1,517%, menunjukkan adanya kemungkinan perlambatan harga menjelang akhir tahun. Secara umum, pola inflasi yang dihasilkan menunjukkan tingkat kestabilan yang cukup baik, dengan variasi antar bulan yang tidak terlalu signifikan.

Hal ini mengindikasikan bahwa model peramalan yang digunakan mampu menghasilkan prediksi yang relatif konsisten dan stabil. Selain itu, hasil peramalan ini dapat menjadi dasar bagi pemerintah dan pelaku ekonomi dalam menyusun kebijakan serta strategi yang lebih tepat untuk mengantisipasi perubahan harga di tahun mendatang.

C. Perbandingan Data Prediksi dan Aktual

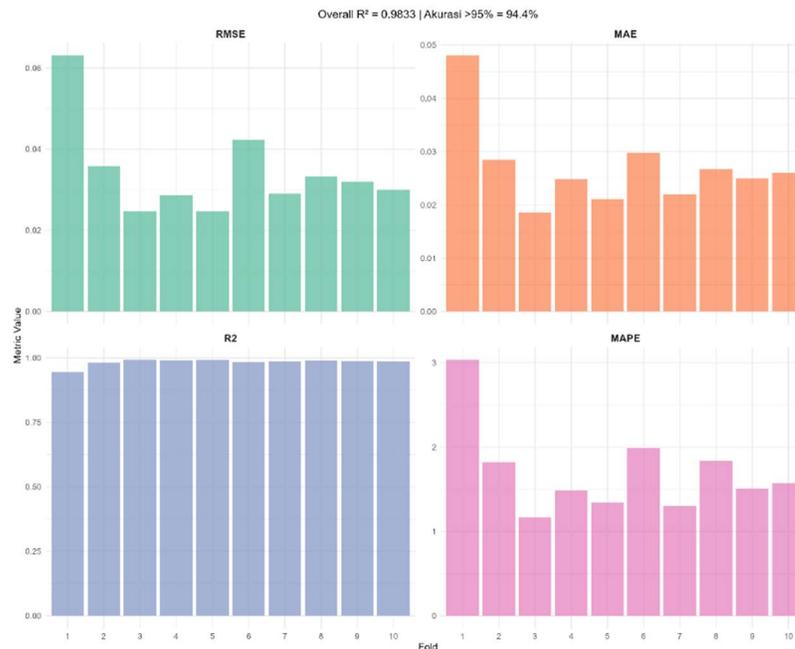


Gambar 3. Plot Garis Diagonal Perbandingan Inflasi Aktual dan Prediksi Model ELM

Gambar 3 menunjukkan distribusi prediksi inflasi bulanan sepanjang tahun 2025, dengan batas target inflasi 1%-2% yang divisualisasikan melalui garis horizontal. Semua titik prediksi berada di dalam rentang target tersebut, mengindikasikan keberhasilan model dalam menjaga konsistensi prediksi sesuai sasaran kebijakan moneter. Prediksi menunjukkan inflasi cenderung stabil. Tidak ada pergeseran signifikan antarbulan yang melampaui batas target. Kondisi ini sangat positif bagi stabilitas ekonomi.

Koefisien determinasi (R^2) yang dihasilkan sebesar 0,9833 semakin memperkuat interpretasi ini. Nilai R^2 mendekati 1 mengindikasikan bahwa 98,3% variasi dalam data aktual dapat dijelaskan oleh model. Dengan kata lain, model memiliki kemampuan prediksi yang sangat baik, meskipun masih terdapat 1,7% variasi yang tidak dijelaskan. Faktor ini bisa disebabkan oleh pengaruh eksternal seperti kebijakan fiskal atau guncangan ekonomi global yang tidak dimasukkan dalam model. Jika ditelaah lebih lanjut, pola prediksi ini konsisten dengan hasil evaluasi model, distribusi prediksi yang rapat terhadap target menunjukkan model sudah cukup optimal untuk digunakan sebagai alat perencanaan ekonomi. Hanya saja, perlu dilakukan pemantauan terhadap potensi anomali yang mungkin muncul akibat faktor eksternal seperti harga komoditas global atau perubahan suku bunga.

D. Analisis Hasil *K-Fold Cross Validation*



Gambar 4. Hasil Evaluasi Model ELM dengan *K-Fold Cross Validation*

Gambar 4 memberikan gambaran tentang stabilitas performa model ELM dalam 10 kali pengujian. Grafik ini menampilkan metrik utama seperti RMSE, MAE, R^2 , dan MAPE untuk masing-masing *fold*. Terlihat bahwa meskipun terdapat variasi antar-*fold*, semua nilai RMSE berada pada kisaran rendah (0,0246–0,063), sedangkan nilai R^2 selalu di atas 0,94. Hal ini menunjukkan bahwa model sangat konsisten dalam memprediksi inflasi, bahkan ketika subset data berbeda.

Nilai MAE rata-rata sebesar 0,027 dan MAPE sekitar 1,71% mengindikasikan bahwa kesalahan prediksi relatif kecil terhadap nilai aktual. Meskipun *Fold* 1 dan *Fold* 6 menunjukkan error sedikit lebih tinggi dibanding yang lain, hal ini masih dalam rentang toleransi. Faktor yang menyebabkan variasi ini kemungkinan terkait distribusi data historis dalam *fold* tertentu, misalnya karena adanya data *outlier* pada periode tertentu.

Secara keseluruhan, hasil *K-Fold Cross Validation* mendukung kesimpulan bahwa ELM adalah metode yang efektif untuk memprediksi inflasi dalam rentang target. Namun, untuk meningkatkan keandalan model pada kondisi ekstrem, diperlukan pengembangan lanjutan melalui penyesuaian struktur jaringan, optimalisasi parameter, serta eksplorasi fungsi aktivasi yang digunakan.

IV. KESIMPULAN

Hasil penelitian menunjukkan bahwa algoritma *Extreme Learning Machine* (ELM) memiliki kinerja yang unggul dalam meramalkan laju inflasi di Indonesia. Hal ini ditunjukkan oleh nilai MAPE yang lebih rendah, RMSE dan MAE yang kecil, serta nilai koefisien determinasi (R^2) yang mendekati 1 pada model ELM. Hasil peramalan laju inflasi Indonesia Jan – Des 2025 menggunakan algoritma ELM sebagai model terbaik didapat pada *fold* ke 3, hasil peramalan menunjukkan bahwa laju inflasi Indonesia pada periode Januari hingga Desember 2025 berada pada kisaran 1,517% hingga 1,761%, dengan rata-rata mendekati 1,663%. Model prediksi menunjukkan pola inflasi yang relatif stabil sepanjang tahun, tanpa fluktuasi ekstrem. Nilai MAPE sebesar 1,71% dan R^2 sebesar 0,9833 mengindikasikan bahwa model memiliki tingkat akurasi yang sangat tinggi dan mampu menjelaskan variasi data dengan baik.

DAFTAR PUSTAKA

- Giusti, A., Widodo, A. W., & Adinugroho, S. (2018). Prediksi Penjualan Mi Menggunakan Metode Extreme Learning Machine (ELM) di Kober Mie Setan Cabang Soekarno Hatta. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(8), 2972-2978.
- Goldani, S. (2024). Robust inflation forecasting using Extreme Learning Machine and hybrid validation approaches. *Journal of Computational Economics*, 32(2), 87–101.
- Gopakumar, K., Kumar, S., & Menon, V. (2015). A comparative study of machine learning algorithms for time series forecasting. *International Journal of Computer Applications*, 119(10), 1–7.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2004). Extreme learning machine: A new learning scheme of feedforward neural networks. *Proceedings of the 2004 IEEE International Joint Conference on Neural Networks*, 2, 985–990.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3), 489–501.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning: With applications in R*. New York: Springer.
- Khan, S., Ahmad, M., & Ullah, A. (2022). Evaluation of machine learning models with K-Fold Cross Validation for economic forecasting. *International Journal of Data Science and Analytics*, 14(2), 101–115.
- Pramadia, Y. S., Martha, Z., Syafriandi, & Mukhti, T. O. (2024). *Application of Extreme Learning Machine Algorithm (ELM) in Forecasting Inflation Rate in Indonesia*. *UNP Journal of Statistics and Data Science*, 2(3), 318–323.
- Sari, R., Hidayat, T., & Prasetyo, B. (2017). Pemanfaatan prediksi harga dalam perencanaan distribusi komoditas pertanian. *Jurnal Ekonomi dan Pembangunan Indonesia*, 18(2), 115–124.
- Wahyuni, R., Hidayat, T., & Prasetyo, B. (2020). Analisis volatilitas inflasi di Indonesia menggunakan model ARCH-GARCH. *Jurnal Ekonomi dan Pembangunan Indonesia*, 21(2), 135–144.
- Widodo, A. W., Gunawan, A., & Lestari, F. (2021). Extreme Learning Machine for predictive analytics in financial data: A case study of economic indicators. *Journal of Artificial Intelligence Research*, 12(4), 221–230.
- Wulandari, D., & Santoso, H. (2023). Enhancing forecasting accuracy of inflation using K-Fold Cross Validation in machine learning models. *Indonesian Journal of Statistics and Its Applications*, 7(1), 45–56.