



## ***Prediction of Inflation Rate in East Java Using the N-BEATS Model and Optuna Optimization***

### **Prediksi Laju Inflasi di Jawa Timur Menggunakan Model N-BEATS dan Optimasi Optuna**

**Mohammad Nizar Riswanda<sup>1\*</sup>, Trimono<sup>2\*</sup>, Wahyu Syaifullah Jauharis Saputra<sup>3</sup>**

<sup>1,2,3</sup>Program Studi Sains Data, Fakultas Ilmu Komputer,  
Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia

E-Mail: <sup>1</sup>mohnizar13@gmail.com, <sup>2</sup>trimono.stat@upnjatim.ac.id,  
<sup>3</sup>wahyu.s.j.saputra.if@upnjatim.ac.id

Received Jun 27th 2025; Revised Jul 24th 2025; Accepted Jul 30th 2025; Available Online Jul 31th 2025, Published Aug 15th 2025

Corresponding Author: Shella Norma Windrasari

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

#### **Abstract**

*Inflation is an important indicator that affects the stability and economic growth of a region. Accurate inflation prediction is needed to support the formulation of appropriate economic policies. This study proposes the use of N-BEATS (Neural Basis Expansion Analysis for Time Series) model optimized with Optuna to predict inflation in East Java Province. The data used is a univariate time series, namely the monthly inflation rate from January 2005 to December 2024, obtained from the Central Bureau of Statistics (BPS). Model performance evaluation is conducted using the Mean Absolute Percentage Error (MAPE) metric. Unlike traditional models such as Autoregressive Integrated Moving Average (ARIMA) and Long Short-Term Memory (LSTM), N-BEATS relies on a feedforward neural network with residual block architecture that is capable of backcast and forecast. Hyperparameter optimization through Optuna has significantly improved the accuracy of the model. Research results show that the optimized N-BEATS achieves a MAPE of 8.97%, better than the basic N-BEATS (11.05%), ARIMA (16.95%), and LSTM (12.23%). This finding indicates that the N-BEATS approach with Optuna is effective in improving inflation prediction accuracy and can be an important tool for economic planning at the regional level.*

**Keyword:** East Java, Inflation, N-BEATS, Optuna, Prediction

#### **Abstrak**

Inflasi merupakan indikator penting yang memengaruhi kestabilan dan pertumbuhan ekonomi suatu wilayah. Prediksi inflasi yang akurat sangat dibutuhkan guna mendukung perumusan kebijakan ekonomi yang tepat. Penelitian ini mengusulkan penggunaan model Neural Basis Expansion Analysis for Time Series (N-BEATS) yang dioptimalkan dengan Optuna untuk memprediksi inflasi di Provinsi Jawa Timur. Data yang digunakan berupa deret waktu univariat, yaitu laju inflasi bulanan dari Januari 2005 hingga Desember 2024, yang diperoleh dari Badan Pusat Statistik (BPS). Evaluasi performa model dilakukan menggunakan metrik Mean Absolute Percentage Error (MAPE). Berbeda dengan model tradisional seperti Autoregressive Integrated Moving Average (ARIMA) dan Long Short-Term Memory (LSTM), N-BEATS mengandalkan jaringan saraf feedforward dengan arsitektur blok residual yang mampu melakukan rekonstruksi masa lalu (backcast) dan prediksi masa depan (forecast). Optimasi hyperparameter melalui Optuna berhasil meningkatkan akurasi model secara signifikan. Hasil Penelitian menunjukkan bahwa N-BEATS teroptimasi mencapai MAPE sebesar 8,97%, lebih baik dibandingkan N-BEATS dasar (11,05%), ARIMA (16,95%), dan LSTM (12,23%). Temuan ini mengindikasikan bahwa pendekatan N-BEATS dengan Optuna efektif dalam meningkatkan akurasi prediksi inflasi dan dapat menjadi alat bantu penting bagi perencanaan ekonomi di tingkat daerah.

**Kata Kunci:** Inflasi, Jawa Timur, N-BEATS, Optuna, Prediksi

#### **1. INTRODUCTION**

Inflasi adalah salah satu parameter penting yang memengaruhi pertumbuhan ekonomi suatu daerah [1]. Inflasi dilihat dari perubahan harga barang dan jasa melalui persentase perubahan indeks harga. Tingkat inflasi dianggap normal jika di bawah 3%. Inflasi yang tinggi dan tidak stabil menunjukkan ketidakstabilan



ekonomi, berdampak pada meningkatnya kemiskinan dan pengangguran [2]. Inflasi juga memengaruhi daya beli masyarakat, inflasi rendah dan stabil menjaga daya beli serta mendukung pertumbuhan ekonomi [3]. Kenaikan harga menyebabkan masyarakat kesulitan memenuhi kebutuhan pokok. Sehingga inflasi tinggi berdampak langsung pada kemiskinan, mendorong masyarakat berpenghasilan rendah mengurangi pengeluaran penting seperti nutrisi dan pendidikan [4]. Oleh karena itu, diperlukan pengendalian inflasi yang efektif, salah satunya melalui prediksi sebagai dasar penyusunan strategi pemerintah. Dengan stabilitas harga akan membantu menjaga kualitas hidup masyarakat.

Mengacu pada data sensus penduduk 2020 dari Badan Pusat Statistik (BPS), menunjukkan sekitar 56% penduduk Indonesia tinggal di Pulau Jawa, dengan kontribusi ekonomi mencapai 57,27% terhadap PDB nasional pada 2023 [5]. Jawa Timur menjadi kontributor ekonomi terbesar kedua secara nasional, dengan sektor utama manufaktur (29,03%), perdagangan (18,18%), dan pertanian (12,80%) [6]. Provinsi ini dipilih sebagai studi kasus karena perannya yang signifikan dalam ekonomi nasional serta keberagaman sektornya yang mencerminkan dinamika inflasi regional. Data yang digunakan dalam penelitian adalah data inflasi Jawa Timur periode Januari 2005 sampai Desember 2024 dari website resmi Badan Pusat Statistik (BPS). Penelitian ini bertujuan untuk menghasilkan model prediksi inflasi yang akurat sebagai upaya mendukung pengambilan keputusan ekonomi berbasis data. Fokus utama dari penelitian ini adalah mengembangkan pendekatan prediktif yang mampu mengantisipasi inflasi secara dini, sehingga dapat membantu perencanaan ekonomi daerah.

Prediksi adalah proses memperkirakan kejadian mendatang berdasarkan data historis [7]. Prediksi deret waktu digunakan untuk memahami pola masa lalu guna memprediksi nilai di masa depan [8]. Penelitian ini memanfaatkan model *Neural Basis Expansion Analysis for Time Series* (N-BEATS) yang dioptimasi menggunakan Optuna. Pendekatan metode ini masih jarang digunakan dalam konteks prediksi inflasi dan dengan optimasi diharapkan mampu meningkatkan akurasi prediksi melalui penyetelan hiperparameter.

Metode tradisional seperti *Autoregressive Integrated Moving Average* (ARIMA), *Long Short-Term Memory* (LSTM), dan Prophet memiliki kelebihan masing-masing, namun terbatas dalam menangani pola inflasi yang kompleks. ARIMA efektif untuk data linier namun tidak adaptif terhadap perubahan struktural. LSTM cocok untuk data berurutan namun membutuhkan data besar. Prophet mudah digunakan tapi cenderung menyederhanakan pola musiman [9-11]. Untuk mengatasi keterbatasan ini, digunakan model prediksi N-BEATS yang lebih fleksibel dan akurat dalam menangani dinamika non-linier dengan efisiensi komputasi tinggi [12].

N-BEATS adalah model deep learning berbasis feedforward neural network yang tidak bergantung pada output sebelumnya untuk memprediksi nilai masa depan [13]. Model ini mengandalkan blok residual dengan dua komponen utama, yaitu *trend* dan *seasonality*, untuk mengenali pola waktu yang kompleks. Berbeda dengan model *Recurrent Neural Network* (RNN), N-BEATS mampu menghindari masalah *vanishing gradient*, yaitu kendala yang membuat model sulit mempelajari pola jangka panjang akibat lemahnya pembaruan bobot saat pelatihan karena arsitekturnya tidak memanfaatkan dependensi berurutan dan menggunakan mekanisme *residual stacking*.

Pemilihan N-BEATS dalam penelitian ini didasarkan pada fleksibilitasnya dalam menangkap pola non-linier secara efisien tanpa memerlukan data stasioner seperti pada ARIMA, serta tanpa membutuhkan data besar dan pelatihan jangka panjang seperti pada LSTM. Sementara itu, meskipun metode seperti Prophet lebih mudah diterapkan, model tersebut cenderung menyederhanakan pola musiman yang kompleks [14-15]. Oleh karena itu, N-BEATS dipilih karena keunggulannya dalam menangani data deret waktu dengan pola musiman dan tren jangka panjang secara bersamaan, serta kemampuannya menghasilkan prediksi yang lebih stabil dan akurat pada data ekonomi yang dinamis seperti inflasi.

Penelitian sebelumnya menunjukkan bahwa model N-BEATS memiliki kinerja prediktif yang unggul dalam melakukan prediksi time series. Beberapa studi penting terkait penggunaan N-BEATS antara lain dilakukan oleh Oreshkin tahun 2021 yang menunjukkan keunggulan N-BEATS dalam peramalan beban listrik jangka menengah [13], serta Dhanalakshmi tahun 2023 yang membandingkan performa N-BEATS dengan LSTM dan ARIMA untuk prediksi harga saham Apple (AAPL) berbasis data historis, dan menunjukkan bahwa N-BEATS memiliki akurasi tertinggi berdasarkan nilai MAPE [15]. Selain itu, Naik tahun 2024 dan Zein tahun 2024 masing-masing menerapkan N-BEATS untuk memprediksi harga saham di sektor teknologi dan perbankan Indonesia, dan menunjukkan akurasi tinggi [16][17], sementara Bulatov tahun 2020 menggunakannya untuk meramalkan harga Bitcoin (BTC) [18].

N-BEATS memiliki beberapa hiperparameter penting seperti jumlah neuron, blok, dan panjang horizon prediksi [19]. Konfigurasi yang tidak tepat dapat menyebabkan overfitting atau underfitting [20]. Untuk menghindari hal tersebut, digunakan metode *Tree-structured Parzen Estimator* (TPE) dari optimasi Optuna untuk mencari kombinasi hiperparameter terbaik [21]. Penelitian ini juga menerapkan *data preprocessing* seperti *data windowing*, normalisasi dan pembagian data guna meningkatkan kinerja prediktif model.


Penelitian ini dilakukan melalui tiga tahap utama: (1) *preprocessing data* historis inflasi Jawa Timur; (2) pembangunan dan evaluasi model N-BEATS dan N-BEATS+Optuna; (3) prediksi inflasi. Evaluasi

dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE) sebagai metrik utama yang biasa digunakan untuk mengevaluasi nilai prediksi dengan mempertimbangkan efek dari nilai aktual [22].

Dengan mengacu pada studi-studi sebelumnya, terlihat bahwa N-BEATS telah terbukti efektif di berbagai domain prediktif. Namun, penerapannya pada konteks prediksi inflasi regional masih sangat terbatas. Sebagian besar penelitian sebelumnya belum mengeksplorasi penerapan N-BEATS dalam bidang ekonomi makro, khususnya inflasi, dan umumnya tidak melibatkan optimasi hiperparameter untuk meningkatkan performa model. Oleh karena itu, penelitian ini menawarkan kontribusi baru dengan menerapkan Model N-BEATS yang dioptimalkan menggunakan Optuna untuk prediksi inflasi di Provinsi Jawa Timur, guna meningkatkan akurasi model, serta dapat membantu para pemangku kepentingan dalam perumusan strategi yang tepat dalam penanganan inflasi secara dini melalui prediksi *time series*.

## 2. MATERIALS AND METHOD

Pada bagian ini, dijelaskan mengenai pendekatan bahan dan metodologi yang digunakan dalam penelitian ini, serta tahapan-tahapan yang dilakukan untuk mencapai tujuan penelitian. Proses penelitian dimulai dengan *literature review*, pengumpulan data, diikuti oleh tahap *preprocessing data*, hingga model yang diterapkan dioptimalkan dan dievaluasi. Serta dilakukan prediksi data baru menggunakan model terbaik. Alur penelitian berikut menggambarkan secara rinci urutan langkah-langkah yang ditempuh dalam penelitian ini yang dapat dilihat pada Gambar 1.



Gambar 1. Metodologi Penelitian

### 2.1. Literature Review

Model N-BEATS telah digunakan secara luas dalam berbagai domain prediksi deret waktu dan menunjukkan performa yang kompetitif dibandingkan dengan model-model konvensional maupun model *deep learning* lainnya. Studi yang dilakukan oleh Oreshkin pada tahun 2021 menunjukkan bahwa N-BEATS berhasil menghasilkan performa superior dalam peramalan beban listrik jangka menengah. Dalam studi tersebut, N-BEATS mampu mencapai nilai MAPE sebesar 3,78% mengungguli beberapa model prediksi lainnya [13]. Selanjutnya, Dhanalakshmi tahun 2023 membandingkan performa N-BEATS, LSTM, dan ARIMA dalam memprediksi harga saham Apple menggunakan data historis dari Yahoo Finance. Model dievaluasi menggunakan tiga metrik utama, yaitu MAPE, MAE, dan RMSE. Hasilnya menunjukkan bahwa N-BEATS menghasilkan MAPE terendah sebesar 0,27%, jauh lebih baik dibandingkan LSTM (13,13%) dan ARIMA (11,80%), yang menegaskan keunggulan akurasi N-BEATS dalam meramalkan pergerakan harga saham [15].

Penelitian lain yang dilakukan oleh Naik tahun 2024 menerapkan N-BEATS untuk meramalkan harga saham S&P 500 dan membandingkannya dengan model LSTM dan *Gated Recurrent Unit* (GRU). Hasil evaluasi menunjukkan bahwa N-BEATS berhasil mencapai MAPE sebesar 1,15%, lebih rendah dibandingkan LSTM (1,70%) dan GRU (1,66%), menegaskan bahwa model ini lebih adaptif terhadap volatilitas pasar [16]. Demikian pula, penelitian oleh Zein tahun 2024 yang memfokuskan pada prediksi harga saham di Indonesia juga mendemonstrasikan keunggulan N-BEATS. Dengan menggunakan dataset harga saham harian, model N-BEATS menghasilkan MAPE sebesar 1,05%, mengungguli metode klasik seperti ARIMA (1,07%) serta metode LSTM (1,40%) dan RNN (1,67%) [17]. Selain itu, Bulatov tahun 2020 menerapkan N-BEATS untuk peramalan harga Bitcoin menggunakan data harian dan membandingkannya dengan model LSTM dan ARIMA. Hasil evaluasi menunjukkan bahwa N-BEATS mencapai MAPE terendah sebesar 2,261%, sedikit lebih baik dibandingkan ARIMA (2,281%) dan secara signifikan lebih baik dari LSTM (2,976%), menegaskan kemampuan N-BEATS dalam menghasilkan prediksi yang lebih akurat pada data dengan volatilitas tinggi seperti cryptocurrency [18].

Berdasarkan hasil-hasil dari penelitian terdahulu tersebut, dapat disimpulkan bahwa N-BEATS memiliki performa prediktif yang unggul dalam berbagai konteks, baik energi, maupun keuangan. Namun, aplikasi model ini untuk prediksi inflasi regional masih sangat terbatas. Oleh karena itu, penelitian ini memanfaatkan model N-BEATS yang dioptimalkan dengan Optuna untuk menjawab tantangan prediksi inflasi secara lebih akurat dalam konteks ekonomi makro regional, khususnya di Provinsi Jawa Timur.

## 2.2. Pengumpulan Data


Penelitian ini menggunakan data sekunder dari situs Badan Pusat Statistik (BPS) Jawa Timur terkait inflasi tahunan di Provinsi Jawa Timur periode Januari 2005 sampai Desember 2024. Data bersifat univariat, yaitu variabel berisi persentase inflasi setiap bulan, yang digunakan sebagai dasar dalam prediksi menggunakan model N-BEATS dan optimasi Optuna.

## 2.3. Preprocessing Data

*Preprocessing data* melibatkan beberapa tahapan untuk meningkatkan kualitas data agar hasil prediksi lebih akurat. Dataset diimpor dari Excel menggunakan pustaka *pandas*, dengan kolom tanggal diubah ke format *datetime* dan dijadikan indeks agar dapat dianalisis berdasarkan deret waktu [23]. Data kemudian diperiksa dan dibersihkan dari nilai yang hilang. Proses *data windowing* diterapkan menggunakan metode *fixed-size sliding window* dengan membuat 12 kolom baru yang merepresentasikan inflasi pada 12 bulan sebelumnya untuk menangkap pola musiman. Teknik ini memungkinkan pembentukan fitur baru berdasarkan nilai masa lalu yang relevan, sehingga hubungan temporal antar waktu dapat dimanfaatkan secara lebih efektif dalam proses prediksi [25-26]. Setelah itu, data yang mengandung nilai kosong akibat pergeseran *window* akan dihapus. Kemudian, dataset dibagi menjadi 80% data latih dan 20% data uji untuk mengukur kemampuan generalisasi model. Selanjutnya, dilakukan normalisasi menggunakan *MinMaxScaler* untuk mengubah skala data ke rentang -1–1 [24].

## 2.4. Penerapan Model N-BEATS

Langkah selanjutnya adalah penerapan model N-BEATS, yaitu arsitektur *deep learning* yang dirancang khusus untuk prediksi deret waktu. Model ini mampu menangkap pola kompleks dalam data dan menghasilkan prediksi inflasi yang akurat. Tahap ini mencakup penentuan struktur awal seperti jumlah lapisan, neuron, dan arsitektur *stacking*, serta pengaturan hiperparameter utama seperti *learning rate*, *batch size*, jumlah neuron per lapisan, dan *epochs* [27]. Arsitektur utama dari algoritma N-BEATS dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur N-BEATS

Arsitektur N-BEATS terdiri dari jaringan multilayer *fully connected* dengan fungsi aktivasi ReLU, di mana setiap blok dalam *stack* memproses input ke arah *forecast* dan *backcast*, dan disusun dengan prinsip *double residual stacking*. Blok-blok ini memungkinkan model menangkap pola musiman dan tren jangka panjang melalui akumulasi prediksi dari setiap lapisan [27]. Prediksi nilai masa depan dalam model univariat dirumuskan sebagai berikut [28]:


$$y \in R^H = [yT + 1, yT + 2, \dots, yT + H] \quad (1)$$

Dimana  $y$  merupakan kumpulan nilai prediksi untuk waktu mendatang.  $T$  adalah waktu observasi terakhir dalam data historis, sedangkan  $H$  menunjukkan jumlah periode yang diprediksi. Vektor prediksi dari  $yT+1$  hingga  $yT+H$  merepresentasikan nilai yang diharapkan setelah titik data terakhir, berdasarkan pola historis yang telah dipelajari model [28].

## 2.5. Optimasi dengan Optuna

Dalam studi ini, Optuna digunakan untuk optimasi hiperparameter karena efisiensinya dalam mengeksplorasi ruang pencarian yang kompleks dan berdimensi tinggi. Optuna menggunakan metode *Tree-*

*Structured Parzen Estimator* (TPE) sebagai teknik sampling, yang lebih efisien dibanding *Grid Search* dan *Random Search* karena berfokus pada area yang menjanjikan dalam ruang hiperparameter [29]. Dengan mempertimbangkan hasil evaluasi sebelumnya, TPE dalam Optuna mempercepat konvergensi menuju konfigurasi optimal dengan lebih sedikit iterasi dan biaya komputasi [30 -31]. Gambar 3 adalah proses dari optimasi optuna.



**Gambar 3.** Proses Optuna

Gambar 3 menjelaskan langkah-langkah utama dalam optimasi hyperparameter menggunakan sampler TPE pada framework Optuna. Hyperparameter model N-BEATS yang dioptimasi meliputi learning rate ( $1e-4$ – $1e-2$ ), jumlah neuron (64–512), serta jumlah layer dan stack (1–4), ditentukan berdasarkan praktik empiris dan hasil eksperimen awal yang menunjukkan bahwa nilai di luar rentang tersebut menyebabkan pelatihan tidak stabil. *Neuron* dan lapisan berperan dalam kapasitas representasi, *learning rate* memengaruhi stabilitas pelatihan, *stack* menentukan kedalaman arsitektur, dan *dropout* membantu menghindari *overfitting*. Optimasi bertujuan meminimalkan error prediksi menggunakan MAPE sebagai fungsi objektif, dengan 100 percobaan menggunakan *Sampler* TPE untuk menjelajahi ruang hyperparameter [31-32].

## 2.6. Evaluasi Model

Evaluasi model digunakan untuk melihat dan menentukan apakah model yang dibuat dapat memprediksi dengan sangat akurat [33]. Evaluasi hasil peramalan dilakukan dengan menggunakan MAPE dengan rumus sebagai berikut [34].

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2)$$

Dimana  $\hat{y}_i$  = nilai prediksi,  $y_i$  = nilai aktual,  $n$  = jumlah data. Kategori dari nilai MAPE dapat ditunjukkan pada Tabel 1, interpretasi nilai MAPE yang diadaptasi dari penelitian yang dilakukan oleh Khairunisa dan Hendikawati tahun 2024 dengan mengkategorikan akurasi prediksi berdasarkan interval nilai MAPE [34].

**Tabel 1.** Kategori Nilai MAPE

| MAPE   | Kategori    |
|--------|-------------|
| <10%   | Sangat Baik |
| 10-20% | Baik        |
| 20-50% | Cukup       |
| >50%   | Buruk       |

Tabel 1 dapat digunakan untuk menafsirkan kinerja model prediksi. Nilai MAPE kurang dari 10% menunjukkan akurasi sangat baik, sedangkan lebih dari 50% menunjukkan model perlu perbaikan [34].

## 2.7. Prediksi Data Baru

Model terbaik berdasarkan evaluasi MAPE akan memprediksi data baru untuk satu tahun ke depan, dengan menggunakan data historis yang telah diproses dan dioptimalkan. Proses prediksi ini dilakukan dengan menggunakan model yang telah dilatih, yang telah mengidentifikasi pola-pola penting dalam data historis inflasi.

### 3. RESULTS AND DISCUSSION


#### 3.1. Analisis Deskriptif Data

Data yang digunakan dalam analisis ini adalah data inflasi tahunan yang diperoleh dari Badan Pusat Statistik (BPS) Jawa Timur. Dataset ini mencakup periode dari Januari 2005 hingga Desember 2024, dengan total 240 entri. Tingkat inflasi menunjukkan perubahan harga rata-rata barang dan jasa yang dikonsumsi masyarakat selama periode tersebut. Setelah data diperoleh, data tersebut dimuat ke dalam python menggunakan google colab untuk analisis lebih lanjut. Berikut adalah tampilan dari data awal inflasi Jawa Timur.

**Tabel 2.** Data Awal

| Tanggal    | Inflasi |
|------------|---------|
| 2005-01-01 | 6,73    |
| 2009-03-01 | 7,71    |
| 2012-06-01 | 4,62    |
| ...        | ...     |
| 2015-09-01 | 6,70    |
| 2019-10-01 | 2,24    |
| 2024-12-01 | 1,51    |

Seperti yang dapat dilihat pada Tabel 2, data ini mencakup informasi inflasi dari Januari 2005 hingga Desember 2024, di mana setiap baris mencerminkan tingkat inflasi bulanan. Berikut adalah hasil visualisasi dari data.



**Gambar 4.** Visualisasi Data Inflasi di Jawa Timur Tahun 2005-2024

Berdasarkan gambar 4, dapat dilihat bahwa inflasi memuncak sangat tinggi pada awal periode, sekitar tahun 2005, dengan inflasi mencapai lebih dari 17%. Setelah itu, inflasi menurun tajam hingga stabil di kisaran 5-7% dalam beberapa tahun. Fluktuasi terjadi selama periode 2010-2018 dengan beberapa puncak kecil, namun tren umum menunjukkan penurunan inflasi secara bertahap. Sejak 2019, inflasi tetap relatif rendah, meskipun terjadi lonjakan sementara sekitar tahun 2022 sebelum turun lagi menjadi mendekati 2% pada akhir 2024.

#### 3.2. Hasil Preprocessing Data

Pada tahap awal *preprocessing data*, perubahan tipe data dilakukan untuk memastikan bahwa kolom tanggal ditafsirkan sebagai tipe tanggal waktu. Hal ini penting untuk analisis deret waktu, sehingga setiap baris data dapat diproses berdasarkan urutan waktu yang benar. Kolom tanggal dikonversi ke format tanggal waktu dan digunakan sebagai indeks. Setelah itu, nilai yang hilang diperiksa untuk mengetahui apakah ada nilai yang tidak lengkap dalam kumpulan data dan memastikan kualitas data sebelum melanjutkan ke analisis lebih lanjut.

Tahap selanjutnya dilakukan proses *data windowing* dengan *windowing* 12 jendela, di mana data inflasi diubah menjadi fitur menggunakan nilai inflasi dari beberapa periode sebelumnya. Proses ini dilakukan untuk membuat fitur lag yang nantinya akan digunakan sebagai input model. Nilai inflasi pada satu periode sebelumnya, dua periode sebelumnya, hingga dua belas periode sebelumnya digunakan sebagai fitur untuk memprediksi nilai inflasi di masa depan. Setelah *windowing*, kolom yang memiliki nilai NaN karena pergeseran data akan dihapus.

Setelah itu, data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Kemudian, data yang awalnya memiliki rentang dari 0 hingga 18 telah melalui proses penskalaan untuk menyesuaikan rentang -1,1 dengan menggunakan *MinMaxScaler*. Hal ini dilakukan untuk meningkatkan kinerja model *machine learning*

yang akan digunakan, sehingga tidak ada fitur yang mendominasi proses pelatihan karena perbedaan skala. Berikut adalah hasil dari *preprocessing data*.

**Tabel 3.** Hasil *Preprocessing Data*

| Tanggal    | Inflasi | Inflasi1 | ... | inflasi11 | inflasi12 |
|------------|---------|----------|-----|-----------|-----------|
| 2006-01-01 | 0,763   | 0,686    | ... | -0,446    | -0,403    |
| 2009-03-01 | -0,212  | -0,160   | ... | -0,078    | -0,149    |
| 2012-06-01 | -0,584  | -0,597   | ... | -0,671    | 0,510     |
| ...        | ...     | ...      | ... | ...       | ...       |
| 2015-09-01 | -0,334  | -0,330   | ... | -0,677    | -0,732    |
| 2019-10-01 | -0,870  | -0,855   | ... | -0,881    | -0,884    |
| 2024-12-01 | -0,958  | -0,798   | ... | -0,950    | -0,951    |

Tabel 3 menampilkan hasil *preprocessing data* yang telah melalui beberapa tahap penting, seperti konversi kolom tanggal ke format waktu, pembuatan fitur lag menggunakan metode *windowing* sebanyak 12 periode sebelumnya, pembagian data dan penskalaan nilai inflasi. Proses ini menghasilkan data *time series* yang siap digunakan untuk pelatihan model prediksi.

**3.3. Penerapan Model N-BEATS**

Model N-BEATS akan dibangun dengan arsitektur bertumpuk, mengoptimalkan jumlah *neuron*, lapisan, *dropout rate*, dan *winfow size*. Memanfaatkan data historis, model ini akan memperkirakan nilai masa depan berdasarkan ukuran jendela 12 titik, yang menangkap tren bulanan. Pengaturan ini bertujuan untuk memprediksi fluktuasi jangka pendek secara efektif sambil mempertahankan fleksibilitas untuk penyesuaian perkiraan jangka panjang. Tabel berikut adalah parameter yang digunakan dalam penerapan N-BEATS.

**Tabel 4.** Parameter N-BEATS

| Parameter Model N-BEATS   |                                           |
|---------------------------|-------------------------------------------|
| Input Size                | 12 ( <i>window_size</i> )                 |
| Theta Size                | 13 ( <i>input_size</i> + <i>horizon</i> ) |
| Batch Size                | 32                                        |
| Horizon                   | 1                                         |
| Neurons                   | 128                                       |
| Layers                    | 2                                         |
| Dropout                   | 0.1                                       |
| Number of Blocks (Stacks) | 2                                         |
| Early Stopping            | Patience 30                               |
| Learning Rate             | Patience 10                               |
| Epochs                    | 100                                       |

Parameter N-BEATS pada Tabel 4 dirancang untuk menyeimbangkan kompleksitas dan efisiensi pelatihan, dengan konfigurasi dua blok bertumpuk, masing-masing terdiri dari dua lapisan berisi 128 neuron dan fungsi aktivasi ReLU untuk menangkap pola non-linier. Penggunaan dropout diterapkan guna mencegah overfitting, sementara arsitektur stacking memungkinkan model menyempurnakan prediksi melalui mekanisme backcast dan forecast. Pelatihan dilakukan selama maksimal 100 epoch, namun berhenti lebih awal pada epoch ke-39 karena penerapan *EarlyStopping* dan penyesuaian *learning rate*, yang membantu proses konvergensi lebih cepat dan stabil. Strategi ini memberikan keseimbangan antara kapasitas model dan generalisasi terhadap data yang belum pernah dilihat, menjadikannya efektif dalam mempelajari pola temporal yang kompleks.

**3.4. Optimasi Optuna**

Optimasi Optuna dengan memanfaatkan TPE sebagai teknik *sampler* berfokus pada pemilihan hiperparameter secara cerdas dengan memodelkan distribusi probabilitas uji coba yang baik dan buruk. Ini secara efisien mengeksplorasi ruang pencarian dengan mempersempit wilayah yang menunjukkan janji berdasarkan uji coba sebelumnya. Dikombinasikan dengan pemangkas Optuna, yang mengakhiri uji coba yang tidak menjanjikan lebih awal, strategi ini mempercepat proses pengoptimalan sekaligus memastikan hasil yang lebih baik, terutama dalam hal meminimalkan kehilangan validasi. Struktur optimasi hiperparameter menggunakan Optuna dirangkum berdasarkan Tabel 5.



**Tabel 5.** Hyperparameter Optuna TPE

| Hyperparameter Optuna TPE |                      |
|---------------------------|----------------------|
| n_neurons                 | 64-512, panjang = 64 |
| n_layers                  | 1-4                  |
| learning_rate             | 1e-4 hingga 1e-2     |
| n_stacks                  | 1-4                  |
| dropout_rate              | 0.0-0.3              |
| Sampler                   | TPE Sampler          |
| n_trials                  | 100                  |

Proses pengoptimalan menggunakan Optuna melibatkan penyetelan parameter utama seperti jumlah neuron, lapisan, *learning rate*, *number of stacks*, dan *dropout rate*. Optuna secara efisien menavigasi ruang hiperparameter untuk menemukan serangkaian nilai yang optimal untuk model N-BEATS. Dalam penelitian ini, proses optimasi dilakukan dengan 100 uji coba. Hasil dari uji coba menghasilkan hasil terbaik pada percobaan ke-52 dengan hiperparameter yang paling optimal, mencapai nilai validasi 0,055. Konfigurasi terbaik termasuk 128 *neuron*, 4 *layer*, 2 *stacks*, *learning rate* 0,004, dan 0,013 *dropout rate*. Uji coba ini mengungguli percobaan yang lain, mengkonfirmasi efektivitas nilai hiperparameter yang dipilih dalam meminimalkan fungsi kerugian, dan dengan demikian meningkatkan daya prediksi model N-BEATS.

### 3.5. Hasil Prediksi Model N-BEATS dan N-BEATS Optuna

Untuk mengevaluasi secara komprehensif kinerja setiap model dalam memperkirakan data inflasi, prediksi dilakukan selama seluruh periode data menggunakan model N-BEATS asli dan model N-BEATS yang dioptimalkan dengan Optuna.

**Gambar 5.** Aktual dan Prediksi Model N-BEATS**Gambar 6.** Aktual dan Prediksi Model N-BEATS+Optuna TPE

Gambar 5 dan 6 menggambarkan hasil prediksi dibandingkan dengan nilai aktual seluruh periode data. Kedua model tampaknya menangkap tren keseluruhan data aktual dengan cukup baik. Namun, setelah diperiksa lebih dekat, perbedaan yang jelas dalam karakteristik prediksi muncul. Prakiraan yang dihasilkan oleh model N-BEATS asli cenderung lebih tersebar, terutama di sekitar puncak dan palung. Sebaliknya, model N-BEATS+Optuna menunjukkan prediksi yang lebih ketat dan lebih tepat pada awal data yang selaras dengan nilai aktual. Ini menunjukkan peningkatan akurasi prediktif sebagai hasil dari proses pengoptimalan hiperparameter menggunakan Optuna, menunjukkan bahwa metode pengoptimalan secara efektif meningkatkan kemampuan model untuk menangkap pola historis dalam data.



### 3.6. Evaluasi Model

Setelah membangun dan melatih model, langkah selanjutnya adalah mengevaluasinya untuk menilai kinerjanya menggunakan metrik MAPE. Sebelum dilakukan evaluasi, data sudah dilakukan *inverse* ke dalam data asli terlebih dahulu. Evaluasi ini bertujuan untuk mengukur seberapa akurat model memprediksi nilai target dibandingkan dengan data aktual. Dalam penelitian ini, model N-BEATS dan N-BEATS+Optuna diuji dan kinerjanya dibandingkan untuk menentukan model mana yang lebih unggul dalam membuat prediksi. Berikut adalah tabel perbandingan evaluasi model.

**Tabel 7.** Hasil Evaluasi Model

| Model          | MAPE   | Kategori    |
|----------------|--------|-------------|
| N-BEATS        | 11,05% | Baik        |
| N-BEATS+Optuna | 8,97%  | Sangat Baik |
| ARIMA          | 16,95% | Baik        |
| LSTM           | 12,23% | Baik        |

Berdasarkan hasil evaluasi pada Tabel 7, model N-BEATS menghasilkan nilai MAPE sebesar 11,05% dan termasuk dalam kategori Baik. Sebaliknya, model N-BEATS+Optuna, yang ditingkatkan melalui pengoptimalan penyetelan hiperparameter menggunakan Optuna TPE, menghasilkan nilai MAPE yang lebih rendah sebesar 8,97%, yang termasuk dalam kategori Sangat Baik. Penurunan kesalahan ini menunjukkan dampak pengoptimalan hiperparameter dalam meningkatkan performa model. Optuna TPE unggul dalam menjelajahi ruang hiperparameter secara sistematis dan efisien untuk menentukan elemen yang mencakup konfigurasi optimal seperti jumlah *neuron*, *layer*, *learning rate*, *stack*, dan *dropout rate*. Pengaturan hiperparameter yang disesuaikan ini memungkinkan model untuk menangkap dan beradaptasi dengan lebih baik dengan dinamika non-linier dan kompleks yang melekat dalam data deret waktu inflasi. Hasilnya, model N-BEATS+Optuna memberikan prediksi yang lebih akurat dengan tingkat kesalahan yang jauh lebih rendah daripada model prediksi inflasi sebelumnya seperti ARIMA dan LSTM. Temuan ini menunjukkan efektivitas mengintegrasikan pengoptimalan hiperparameter berbasis Optuna ke dalam kerangka kerja N-BEATS untuk prediksi deret waktu ekonomi.

### 3.7. Memprediksi Data Baru

Setelah menemukan bahwa model N-BEATS+Optuna berkinerja lebih baik, langkah selanjutnya adalah memprediksi data baru, yaitu prediksi inflasi untuk satu tahun kedepan berdasarkan hasil pemodelan dan data historis yang digunakan. Hasil prediksi penting untuk memberikan gambaran tentang kemungkinan pergerakan tingkat inflasi di masa depan, yang dapat digunakan oleh pengambil kebijakan dan pelaku ekonomi untuk merencanakan dan memitigasi risiko dengan lebih baik. Prediksi ini dibuat dengan menggunakan parameter optimal yang diperoleh dari proses optimasi model sebelumnya.

**Tabel 8.** Hasil Prediksi Data Baru

| Tanggal    | Inflasi |
|------------|---------|
| 2025-01-01 | 1,50    |
| 2025-02-01 | 1,63    |
| 2025-03-01 | 1,77    |
| 2025-04-01 | 2,04    |
| 2025-05-01 | 2,13    |
| 2025-06-01 | 2,28    |
| 2025-07-01 | 2,59    |
| 2025-08-01 | 2,49    |
| 2025-09-01 | 2,10    |
| 2025-10-01 | 1,95    |
| 2025-11-01 | 1,67    |
| 2025-12-01 | 1,86    |

Berdasarkan hasil prediksi pada Tabel 8, inflasi di Jawa Timur diperkirakan akan mengalami fluktuasi sepanjang tahun 2025. Prediksi ini menunjukkan adanya tren kenaikan inflasi secara bertahap dari awal tahun hingga pertengahan tahun, kemudian diikuti oleh penurunan menjelang akhir tahun. Inflasi mengalami tren naik sejak awal tahun hingga mencapai puncak 2,59% pada Juli, lalu menurun hingga November menjadi 1,67%, sebelum sedikit naik kembali pada Desember ke angka 1,86%. Secara keseluruhan, inflasi diprediksi tetap terkendali dan stabil sepanjang tahun, namun tetap perlu waspada terhadap faktor eksternal seperti kenaikan harga energi global, gangguan distribusi, dan perubahan kebijakan fiskal yang dapat menyebabkan lonjakan inflasi secara tiba-tiba.

Hasil prediksi menunjukkan bahwa model N-BEATS yang dioptimasi dengan Optuna mampu menangkap pola musiman dan memprediksi fluktuasi inflasi tahunan secara akurat. Kenaikan inflasi di

pertengahan tahun kemungkinan dipengaruhi oleh siklus hari libur, sementara penurunan di akhir tahun mencerminkan normalisasi harga. Temuan ini selaras dengan studi oleh Naik tahun 2024 dan Dhanalakshmi tahun 2023, yang membuktikan keunggulan N-BEATS dalam mengolah data musiman dan non-linier. N-BEATS dengan penambahan optimasi Optuna terbukti lebih akurat dibanding dengan model N-BEATS dasar, ARIMA dan LSTM yang rentan terhadap noise dan perubahan struktural. Hasil ini memberikan implikasi penting bagi pembuat kebijakan dalam merancang strategi pengendalian harga dan anggaran berbasis data. Meski demikian, keterbatasan model yang hanya menggunakan data univariat menjadi catatan penting. Untuk meningkatkan akurasi dan ketahanan model, penelitian selanjutnya disarankan mengintegrasikan pendekatan multivariat dan mengeksplorasi metode ensemble atau hybrid guna memperkuat prediksi serta interpretabilitas model.

#### 4. CONCLUSION

Penelitian ini menunjukkan bahwa model N-BEATS yang dioptimalkan dengan Optuna secara signifikan meningkatkan kinerja prediksi inflasi Jawa Timur dibandingkan dengan model konvensional dan model N-BEATS yang tidak dioptimalkan. Model N-BEATS yang dioptimasi dengan Optuna mencapai penurunan MAPE dari 11,05% menjadi 8,97%, mengungguli model-model prediksi inflasi sebelumnya seperti ARIMA (16,95%), dan LSTM (12,23%). Peningkatan ini didorong oleh penyetelan hyperparameter Optuna yang efisien dalam mengoptimalkan parameter-parameter utama termasuk jumlah *neuron*, *layer*, *learning rate*, *stacks*, dan *dropout rate*, sehingga memungkinkan model ini untuk lebih baik dalam menangkap perilaku data inflasi yang kompleks dan tidak linier. Meskipun penelitian ini berfokus pada prediksi univariat, penelitian selanjutnya di masa depan dapat mengeksplorasi integrasi dengan pendekatan multivariat, dengan memasukkan indikator ekonomi eksternal seperti harga komoditas, biaya bahan bakar, atau nilai tukar. Selain itu, potensi penggunaan teknik ensemble dan model hibrida dapat dilakukan untuk meningkatkan akurasi prediksi. Memperluas analisis ke berbagai wilayah dan periode waktu yang lebih panjang juga akan meningkatkan penerapan dan ketahanan model di berbagai lingkungan ekonomi.

#### REFERENCES

- [1] E. F. B. Simanungkalit, "Pengaruh inflasi terhadap pertumbuhan ekonomi di Indonesia," *Journal of Management*, vol. 13, no. 3, pp. 327–340, 2020, doi: 10.35508/jom.v13i3.3311.
- [2] A. Salim and A. Purnamasari, "Pengaruh inflasi terhadap pertumbuhan ekonomi Indonesia," *Ekonomika Sharia: Jurnal Pemikiran dan Pengembangan Ekonomi Syariah*, vol. 7, no. 1, pp. 17–28, 2021.
- [3] A. N. Ramadanti, E. I. Zulfa, N. M. Sunariadi, and D. C. R. Novitasari, "Peramalan pergerakan inflasi di Jawa Timur dengan menggunakan metode triple exponential smoothing," *J. Matematika Sains dan Teknologi*, vol. 22, no. 2, pp. 40–49, Mar. 2022, doi: 10.33830/jmst.v22i2.1346.2021.
- [4] S. N. Fadhilah, F. Indriyani, and S. Suharsono, "Pengaruh inflasi, pertumbuhan ekonomi, jumlah penduduk terhadap kesejahteraan dengan ZIS sebagai variabel moderasi," *Almaal*, vol. 3, no. 2, p. 154, Jan. 2022, doi: 10.31000/almaal.v3i2.4630.
- [5] A. Safira, R. A. Dhiya'ulhaq, I. Fahmiyah, and M. Ghani, "Spatial impact on inflation of Java Island prediction using autoregressive integrated moving average (ARIMA) and generalized space-time ARIMA (GSTARIMA)," *MethodsX*, vol. 13, p. 102867, Dec. 2024, doi: 10.1016/j.mex.2024.102867.
- [6] M. A. S. Izza, F. L. Wachdah, and M. Yasin, "Analisis pertumbuhan ekonomi di provinsi Jawa Timur tahun 2022," *Trending*, vol. 1, no. 3, pp. 42–50, Jun. 2023, doi: 10.30640/trending.v1i3.1122.
- [7] M. L. Ashari and M. Sadikin, "Prediksi data transaksi penjualan time series menggunakan regresi LSTM," *J. Nas. Pendidik. Teknik. Inform.*, vol. 9, no. 1, p. 1, Apr. 2020, doi: 10.23887/janapati.v9i1.19140.
- [8] M. Idhom, A. Fauzi, T. Trimono, and P. Riyantoko, "Time series regression: Prediction of electricity consumption based on number of consumers at National Electricity Supply Company," *TEM Journal*, pp. 1575–1581, Aug. 2023, doi: 10.18421/tem123-39.
- [9] G. Alomani, M. Kayid, and M. F. Abd El-Aal, "Global inflation forecasting and uncertainty assessment: Comparing ARIMA with advanced machine learning," *Journal of Radiation Research and Applied Sciences*, vol. 18, no. 2, p. 101402, Jun. 2025, doi: 10.1016/j.jrras.2025.101402.
- [10] T. L. Narayanaa, R. R. Skandarsini, S. J. Ida, S. R. Sabapathy, and P. Nanthitha, "Inflation prediction: A comparative study of ARIMA and LSTM models across different temporal resolutions," in *2023 3rd International Conference on Innovative Mechanisms for Industry Applications (ICIMIA)*, Bengaluru, India, Dec. 2023, pp. 1390–1395, doi: 10.1109/icimia60377.2023.10425970.
- [11] B. Subburaj and A. Agrawal, "Prophet and NeuralProphet compared with Indian inflation data," in *2024 11th International Conference on Signal Processing and Integrated Networks (SPIN)*, Noida, India, Mar. 2024, pp. 205–210, doi: 10.1109/spin60856.2024.10512170.

- [12] K. Xu, J. Zhang, J. Huang, H. Tan, X. Jing, and T. Zheng, "Forecasting visitor arrivals at tourist attractions: A time series framework with the N-BEATS for sustainable tourism," *Sustainability*, vol. 16, no. 18, p. 8227, Sep. 2024, doi: 10.3390/su16188227.
- [13] B. N. Oreshkin, G. Dudek, P. Pełka, and E. Turkina, "N-BEATS neural network for mid-term electricity load forecasting," *Applied Energy*, vol. 293, p. 116918, Jul. 2021, doi: 10.1016/j.apenergy.2021.116918.
- [14] M. Melina et al., "Comparative analysis of time series forecasting models using ARIMA and neural network autoregression methods," *Barekeng: J. Math. & App.*, vol. 18, no. 4, pp. 2563–2576, Oct. 2024, doi: 10.30598/barekengvol18iss4pp2563-2576.
- [15] R. Dhanalakshmi, R. Harsh, and S. B. Prathiba, "Predicting the Price of Stock Using Deep Learning Algorithms," in 2023 International Conference on System, Computation, Automation and Networking (ICSCAN), PUDUCHERRY, India: IEEE, Nov. 2023, pp. 1–6. doi: 10.1109/ICSCAN58655.2023.10395609.
- [16] B. S. Naik et al., "Stock price forecasting using N-BEATS deep learning architecture," *J. Sci. Res. Rep.*, vol. 30, no. 9, pp. 483–494, Sep. 2024, doi: 10.9734/jsrr/2024/v30i92373.
- [17] M. H. Zein, N. Yudistira, and P. P. Adikara, "Indonesian stock price prediction using neural basis expansion analysis for interpretable time series method," *JICT*, vol. 23, no. 3, pp. 361–392, Jul. 2024, doi: 10.32890/jict2024.23.3.1.
- [18] A. Bulatov, "Forecasting bitcoin prices using N-BEATS deep learning architecture," Sheridan College Student Thesis, 2020.
- [19] S. Martín-Suazo et al., "Deep learning methods for multi-horizon long-term forecasting of harmful algal blooms," *Knowledge-Based Systems*, vol. 301, p. 112279, Oct. 2024, doi: 10.1016/j.knosys.2024.112279.
- [20] A. K. P. Anil and U. K. Singh, "An optimal solution to the overfitting and underfitting problem of healthcare machine learning models," *J Syst Eng Inf Technol*, vol. 2, no. 2, pp. 77–84, Oct. 2023, doi: 10.29207/joseit.v2i2.5460.
- [21] S. Watanabe and F. Hutter, "c-TPE: Tree-structured Parzen estimator with inequality constraints for expensive hyperparameter optimization," in *Proc. 32nd Int. Joint Conf. Artificial Intelligence (IJCAI)*, Macau, SAR China, Aug. 2023, pp. 4371–4379, doi: 10.24963/ijcai.2023/486.
- [22] T. Trimono, A. Sonhaji, and U. Mukhaiyar, "Forecasting farmer exchange rate in Central Java Province using vector integrated moving average," *Medstat*, vol. 13, no. 2, pp. 182–193, Dec. 2020, doi: 10.14710/medstat.13.2.182-193.
- [23] T. M. Fahrudin, P. A. Riyantoko, K. M. Hindrayani, and I. G. S. Mas Diyasa, "Exploratory data analysis pada kasus COVID-19 di Indonesia menggunakan HiveQL dan Hadoop environment," *Santika*, vol. 1, pp. 115–123, Nov. 2020, doi: 10.33005/santika.v1i0.32.
- [24] T. Ferdousi, L. W. Cohnstaedt, and C. M. Scoglio, "A windowed correlation-based feature selection method to improve time series prediction of dengue fever cases," *IEEE Access*, vol. 9, pp. 141210–141222, 2021, doi: 10.1109/ACCESS.2021.3120309.
- [25] F. Nurcahyadi and A. Hermawan, "Optimizing windowing techniques to improve the accuracy of artificial neural networks in predicting outpatient visits," *Ilk. J. Ilm.*, vol. 16, no. 2, pp. 172–183, Aug. 2024, doi: 10.33096/ilkom.v16i2.2254.172-183.
- [26] D. A. Prasetya, A. P. Sari, M. Idhom, and A. Lisanthoni, "Optimizing clustering analysis to identify high-potential markets for Indonesian tuber exports," *Indonesian Journal of Electronics, Electromedical Engineering, and Medical Informatics*, vol. 7, no. 1, pp. 113–122, 2025, doi: 10.35882/skzqbd57.
- [27] A. Karamchandani, A. Mozo, S. Vakaruk, S. Gómez-Canaval, J. E. Sierra-García, and A. Pastor, "Using N-BEATS ensembles to predict automated guided vehicle deviation," *Appl Intell*, vol. 53, no. 21, pp. 26139–26204, Nov. 2023, doi: 10.1007/s10489-023-04820-0.
- [28] B. N. Oreshkin, D. Carпов, N. Chapados, and Y. Bengio, "N-BEATS: Neural basis expansion analysis for interpretable time series forecasting," *ICLR*, 2020.
- [29] Z. A. Riyadi, M. H. Husen, L. A. Lubis, and T. K. Ridwan, "The implementation of TPE-Bayesian hyperparameter optimization to predict shear wave velocity using machine learning: Case study from X field in Malay Basin," *Petroleum and Coal*, vol. 64, no. 2, pp. 467–488, 2022.
- [30] G. Rong et al., "Comparison of tree-structured Parzen estimator optimization in three typical neural network models for landslide susceptibility assessment," *Remote Sensing*, vol. 13, no. 22, p. 4694, Nov. 2021, doi: 10.3390/rs13224694.
- [31] M. M. Miah, K. K. Hyun, S. P. Mattingly, and H. Khan, "Estimation of daily bicycle traffic using machine and deep learning techniques," *Transportation*, vol. 50, no. 5, pp. 1631–1684, Oct. 2023, doi: 10.1007/s11116-022-10290-z.

- 
- [32] J.-P. Lai, Y.-L. Lin, H.-C. Lin, C.-Y. Shih, Y.-P. Wang, and P.-F. Pai, "Tree-based machine learning models with Optuna in predicting impedance values for circuit analysis," *Micromachines*, vol. 14, no. 2, p. 265, Jan. 2023, doi: 10.3390/mi14020265.
  - [33] A. T. Damaliana, K. M. Hindrayani, and T. M. Fahrudin, "Hybrid Holt Winter-Prophet method to forecast the number of foreign tourist arrivals through Bali's Ngurah Rai Airport," *IJDASEA Int'l J. of DA. DE. DA.*, vol. 3, no. 2, pp. 21–32, May 2024, doi: 10.33005/ijdasea.v3i2.8.
  - [34] N. K. Khairunisa and P. Hendikawati, "Long short-term memory and gated recurrent unit modeling for stock price forecasting," *JMSK*, vol. 21, no. 1, pp. 321–333, Sep. 2024, doi: 10.20956/j.v21i1.35930.
  - [35] U. Orji and E. Ukwandu, "Machine learning for an explainable cost prediction of medical insurance," *Machine Learning with Applications*, vol. 15, p. 100516, Mar. 2024, doi: 10.1016/j.mlwa.2023.100516.
  - [36] S. Sengupta, T. Chakraborty, and S. K. Singh, "Forecasting CPI inflation under economic policy and geopolitical uncertainties," *International Journal of Forecasting*, p. S016920702400092X, Sep. 2024, doi: 10.1016/j.ijforecast.2024.08.005