

# Peramalan Jumlah Penumpang Kereta Api Nasional dengan Model *Hybrid* ARIMAX-XGBoost Menggunakan *Dummy* Intervensi

Rafi Kamindra<sup>1</sup>, Dadan Dasari<sup>2</sup>, Fitriani Agustina<sup>3</sup>

<sup>1,2,3</sup>Program Studi Matematika, Fakultas Pendidikan Matematika dan Ilmu Pengetahuan Alam, Universitas Pendidikan Indonesia  
Jalan. Dr. Setiabudi No. 229, Bandung 40154, Indonesia.

Korespondensi; Fitriani Agustina, Email: fitriani

## Abstrak

Keberadaan guncangan struktural (*structural break*) pada data deret waktu menyebabkan metode peramalan linear konvensional memiliki keterbatasan dalam menghasilkan akurasi yang tinggi. Keterbatasan ini sangat terlihat pada data mobilitas penumpang kereta api nasional yang merekam fluktuasi ekstrem dan perubahan level secara permanen akibat krisis makro di masa lalu, seperti pandemi COVID-19. Penelitian ini bertujuan membangun model peramalan yang adaptif menggunakan pendekatan *Hybrid* yang menggabungkan model statistik linear *Autoregressive Integrated Moving Average with Exogenous Variables* (ARIMAX) dan algoritma *Machine Learning* non-linear *eXtreme Gradient Boosting* (XGBoost). Metodologi dilakukan dalam dua tahap, yaitu estimasi komponen linear dan dampak kebijakan menggunakan ARIMAX dengan empat variabel *dummy* intervensi, dilanjutkan dengan pemodelan sisaan (*residual*) yang mengandung pola non-linear menggunakan XGBoost. Hasil analisis menunjukkan model linear terbaik adalah ARIMAX(0,1,3) dengan residu yang terbukti tidak berdistribusi normal, menjustifikasi penggunaan XGBoost pada tahap kedua. Evaluasi kinerja pada data uji (*out-of-sample*) membuktikan bahwa model *Hybrid* ARIMAX-XGBoost lebih unggul dibandingkan model ARIMAX tunggal, dengan penurunan nilai RMSE sebesar 2,76% dan perbaikan akurasi MAPE sebesar 2,81%, sehingga pendekatan ini lebih efektif digunakan untuk perencanaan operasional transportasi di era pemulihan pasca-pandemi.

**Kata Kunci:** ARIMAX, Jumlah Penumpang Kereta Api, Model *Hybrid*, Peramalan, Variabel *Dummy* Intervensi, XGBoost.

## Abstract

The existence of structural breaks in time series data causes conventional linear forecasting methods to have limitations in producing high accuracy. This limitation is highly evident in the national train passenger mobility data, which records extreme fluctuations and permanent level shifts due to past macro crises, such as the COVID-19 pandemic. This study aims to build an adaptive forecasting model using a Hybrid approach combining the linear statistical model *Autoregressive Integrated Moving Average with Exogenous Variables* (ARIMAX) and the non-linear *Machine Learning* algorithm *eXtreme Gradient Boosting* (XGBoost). The methodology was conducted in two stages, estimating linear components and policy impacts using ARIMAX with four intervention dummy variables, followed by modeling the residuals containing non-linear patterns using XGBoost. The analysis results indicated that the best linear model was ARIMAX(0,1,3) with residuals proven to be non-normally distributed, justifying the use of XGBoost in the second stage. Performance evaluation on testing data (*out-of-sample*) demonstrated that the Hybrid ARIMAX-XGBoost model outperformed the single ARIMAX model, with a 2.76% decrease in RMSE and a 2.81% improvement in MAPE accuracy, proving that this approach is more effective for transportation operational planning in the post-pandemic recovery era.

**Keywords:** ARIMAX, Train Passenger Volume, Hybrid Model, Forecasting, Intervention Dummy Variables, XGBoost.

## Pendahuluan

Transportasi publik, khususnya kereta api, merupakan elemen krusial dalam menunjang mobilitas nasional berkat keunggulan kapasitas massal dan efisiensi waktu tempuh [1]. Dalam manajemen operasional perkeretaapian modern, kemampuan mengantisipasi permintaan penumpang secara presisi adalah mutlak. Kegagalan estimasi berimplikasi langsung pada inefisiensi manajerial, prediksi yang terlalu rendah (*under-forecasting*) memicu penumpukan penumpang, sementara prediksi yang terlalu tinggi (*over-forecasting*) menyebabkan pemborosan alokasi sumber daya dan hilangnya potensi pendapatan [2]. Tantangan peramalan ini menjadi sangat kompleks pada rentang pengamatan 2017-2025 akibat adanya patahan struktural (*structural break*) radikal yang dipicu oleh guncangan makro pandemi COVID-19. Kebijakan pembatasan mobilitas yang fluktuatif merusak pola musiman standar dan menciptakan distorsi ekstrem pada deret waktu mobilitas penumpang.

Metode peramalan linear konvensional yang hanya mengandalkan ekstrapolasi tren masa lalu terbukti gagal menangkap pergeseran perilaku yang drastis ini [3]. Sebagai solusi, pendekatan ekonometrika seperti Autoregressive Integrated Moving Average with Exogenous Variables (ARIMAX) sering diterapkan. ARIMAX menawarkan keunggulan metodologis dengan mengintegrasikan variabel *dummy* intervensi untuk memodelkan dampak guncangan pandemi dan periode liburan secara eksplisit [3]. Meskipun mampu mengenali kapan terjadinya peristiwa luar biasa, ARIMAX memiliki kelemahan fundamental pada asumsi linearitas yang kaku. Dinamika perilaku penumpang di era pemulihan pasca-pandemi mengandung volatilitas non-linear yang kompleks. Ketika model ARIMAX dipaksakan untuk menyerap fluktuasi acak ini, informasi penting gagal diproses dan tertinggal di dalam komponen sisaan (*residual*). Mengabaikan sisaan yang tidak lagi bersifat *white noise* ini sama dengan mereduksi akurasi prediksi secara substansial [4].

Untuk memecahkan kebuntuan model parametrik tunggal tersebut, diperlukan kerangka kerja hibrida (*Hybrid Model*) yang mampu mengekstraksi sisa informasi dari residual linear. Prinsip dasar pendekatan ini adalah pembagian beban kerja (*division of labor*): model statistik mengkarantina komponen linear dan intervensi makro, sementara algoritma *machine learning* difungsikan untuk memetakan sisaan non-linear [4]. Nilai kebaruan (*novelty*) dari penelitian ini terletak pada penggunaan algoritma eXtreme Gradient Boosting (XGBoost) pada tahap kedua pemodelan deret waktu penumpang. Dibandingkan dengan algoritma berbasis jaringan saraf tiruan yang rentan mengalami *overfitting* pada data transportasi, XGBoost memiliki superioritas komputasi dalam menangani pencilan (*outliers*) melalui mekanisme regularisasi matematis dan ekspansi deret Taylor orde kedua. XGBoost berfungsi sebagai korektor presisi yang mempelajari bias dari ARIMAX dan mengoreksi prediksi akhir.

Sinergi antara interpretabilitas ARIMAX terhadap dampak kebijakan makro dan kekuatan adaptif XGBoost terhadap volatilitas mikro akan menghasilkan dekomposisi peramalan yang lebih tangguh (*robust*). Oleh karena itu, penelitian ini bertujuan untuk memodelkan komponen linear dan dampak guncangan pandemi menggunakan ARIMAX dengan variabel *dummy* intervensi, serta menerapkan algoritma XGBoost untuk memodelkan pola non-linear pada sisaan ARIMAX guna mengevaluasi peningkatan akurasi peramalan jumlah penumpang kereta api nasional.

## Landasan Teori

### Model ARIMAX dan Intervensi *Dummy* Intervensi

Model *Autoregressive Integrated Moving Average with Exogenous Variables* (ARIMAX) merupakan perluasan dari model ARIMA yang memodelkan pengaruh variabel independen atau eksogen ( $X_t$ ) terhadap variabel dependen dalam suatu deret waktu [5]. Dalam analisis deret waktu yang mengalami guncangan struktural, variabel *dummy* digunakan untuk mengkuantifikasi kejadian kualitatif (intervensi) yang bersifat "satu kali" namun berdampak signifikan terhadap variabel hasil, seperti

penerapan kebijakan pembatasan sosial [6]. Persamaan model ARIMAX dengan variabel eksogen secara matematis dirumuskan sebagai berikut:

$$\Phi_p(B)(1-B)^d(Y_t - \sum_{i=1}^k \beta_i X_{i,t}) = \Theta_q(B)a_t \quad (1)$$

Dimana,

- $Y_t$  : Nilai observasi (variable dependen) pada periode ke- $t$ .
- $X_{i,t}$  : Nilai variabel eksogen (*dummy* intervensi) ke- $i$  pada waktu ke- $t$ .
- $\beta_i$  : Koefisien regresi yang mengukur besaran dampak dari variable intervensi ke- $i$ .
- $\Phi_p(B)$  : Operator *Autoregressive* (AR) non-musiman orde  $p$ , yang memetakan korelasi data dengan nilai masa lalunya.
- $\Theta_q(B)$  : Operator *Moving Average* (MA) non-musiman orde  $q$ , yang memetakan korelasi data dengan nilai sisaan masa lalu.
- $(1-B)^d$  : Operator pembedaan (*differencing*) orde  $d$  yang digunakan untuk menstabilkan rata-rata data (mencapai stasioneritas).
- $a_t$  : Sisaan (*residual*) yang diasumsikan bersifat acak murni (*white noise*) dengan varians konstan.

Persamaan ini menunjukkan bahwa filter ARIMA diterapkan pada sisaan hasil regresi variabel eksogen, di mana nilai ramalan  $Y_t$  dibentuk oleh komponen deterministik yang dijelaskan oleh efek intervensi dan komponen stokastik dari dinamika deret waktu [5].

#### Algoritma *eXtreme Gradient Boosting* (XGBoost)

XGBoost adalah algoritma *machine learning* berbasis *ensemble* yang dikembangkan dari konsep *Gradient Boosting Decision Tree* (GBDT) yang dirancang untuk menjadi sangat efisien dan fleksibel [7]. Tujuan utama algoritma ini adalah meminimalkan fungsi objektif terregularisasi yang terdiri dari fungsi kerugian (*loss function*) untuk mengukur selisih prediksi dengan nilai aktual, dan fungsi regularisasi ( $\Omega$ ) untuk mengontrol kompleksitas pohon dan mencegah *over-fitting* [7]. Fungsi objektif pada XGBoost didefinisikan sebagai:

$$L^{(t)} = \sum_{i=1}^n l(e_i, \hat{e}_i^{(t)}) + \sum_{k=1}^t \Omega(f_k) \quad (2)$$

Dimana,

- $L^{(t)}$  : Fungsi objektif total yang harus diminimalkan pada iterasi ke- $t$ .
- $l(e_i, \hat{e}_i^{(t)})$  : Fungsi kerugian (*loss function*) yang mengukur selisih antara nilai aktual ( $e_i$ ) dan nilai yang diprediksi oleh model ( $\hat{e}_i$ ) pada iterasi tersebut.
- $\Omega(f_k)$  : Suku regularisasi yang berfungsi mengontrol kompleksitas pohon keputusan (seperti kedalaman dan bobot daun) untuk mencegah model menghafal *noise* (*over-fitting*).
- $f_k$  : Fungsi pohon keputusan independen yang ditambahkan pada langkah ke- $k$  untuk mengoreksi kesalahan (residu) dari langkah sebelumnya.

Keunggulan utama XGBoost terletak pada penggunaan ekspansi deret Taylor orde kedua untuk mengaproksimasi fungsi kerugian, yang memungkinkannya memodelkan residu yang memiliki pola fluktuatif dan non-linear secara cepat dan presisi [7].

#### Pendekatan *Hybrid* ARIMAX-XGBoost

Pembenaran teoretis dari pendekatan *hybrid* didasarkan pada asumsi dekomposisi bahwa suatu observasi deret waktu ( $Y_t$ ) tersusun atas penjumlahan komponen linear ( $L_t$ ) dan komponen non-linear ( $N_t$ ) [8].

$$Y_t = L_t + N_t \quad (3)$$

Dimana,

- $Y_t$  : Total nilai deret waktu aktual pada waktu ke- $t$ .  
 $L_t$  : Komponen linear yang merepresentasikan tren utama, pola musiman, dan guncangan makro.  
 $N_t$  : Komponen non-linear yang merepresentasikan volatilitas kompleks dan pola yang tidak teratur.

Pendekatan ini bekerja dalam skema dua tahap strategis. Pada tahap linear, model statistik (ARIMAX) digunakan sebagai pra-filter untuk menangkap tren utama, musiman, dan dampak intervensi makro [8]. Tahap non-linear mengasumsikan bahwa sisaan ( $e_t = Y_t - \hat{L}_t$ ) dari model linear masih mengandung pola informasi non-linear yang tidak dapat dijelaskan oleh persamaan linear [8]. Algoritma XGBoost kemudian dilatih secara khusus untuk memprediksi sisaan tersebut, sehingga model *hybrid* tidak membuang informasi yang tersisa pada galat (*error*), melainkan mengolahnya kembali untuk meningkatkan presisi prediksi akhir [8].

## Bahan dan Metode

### Data Penelitian

Penelitian ini menggunakan data sekunder deret waktu berupa jumlah penumpang kereta api nasional bulanan (dalam satuan ribuan orang) yang bersumber dari publikasi resmi Badan Pusat Statistik (BPS) Indonesia [9]. Rentang observasi mencakup periode Januari 2017 hingga Agustus 2025 dengan total 104 data.

Untuk mengevaluasi keandalan model dan mencegah *over-fitting*, dataset dipartisi menggunakan rasio 80:20 [10]. Data latih (*training set*) dialokasikan pada periode Januari 2017 hingga Desember 2023 (84 observasi) untuk estimasi parameter dan pelatihan model. Data uji (*testing set*) dialokasikan pada periode Januari 2024 hingga Agustus 2025 (20 observasi) untuk memvalidasi kinerja generalisasi model (*out-of-sample*) dalam menangkap siklus musiman secara penuh.

### Variabel Penelitian dan Intervensi


Variabel dependen ( $Y_t$ ) adalah total penumpang kereta api bulanan. Mengingat data historis merekam guncangan ekstrem akibat krisis makro, penelitian ini menggunakan empat variabel eksogen berupa *dummy* intervensi (bernilai 0 atau 1) untuk mengisolasi efek kalender dan kebijakan pandemi. Definisi operasional variabel eksogen disajikan pada Tabel 1.

**Tabel 1** Definisi Operasional Variabel *Dummy* Intervensi.

| Variabel Eksogen         | Keterangan                                                                                                                        |
|--------------------------|-----------------------------------------------------------------------------------------------------------------------------------|
| $X_1$ (Era Covid)        | Merepresentasikan <i>level shift</i> pandemi. Bernilai 1 untuk Maret 2020 – Desember 2022; 0 untuk lainnya                        |
| $X_2$ (Pembatasan Ketat) | Merepresentasikan <i>shock</i> ekstrem (PSBB/PPKM Darurat). Bernilai 1 untuk April-Mei 2020 & Juli-Agustus 2021; 0 untuk lainnya. |
| $X_3$ (Libur Juli)       | Musiman libur sekolah. Bernilai 1 setiap bulan Juli (kecuali ditiadakan pada 2020 & 2021); 0 untuk lainnya.                       |
| $X_4$ (Nataru)           | Musiman akhir tahun. Bernilai 1 setiap bulan Desember (kecuali ditiadakan pada 2020); 0 untuk lainnya.                            |

### Prosedur Analisis

Pemodelan dilakukan secara sekuensial melalui pendekatan *two-stage hybrid*. Alur komprehensif dari metodologi ini dapat dilihat pada Gambar 1.



**Gambar 1.** Diagram Alir Dekomposisi Model *Hybrid* ARIMAX-XGBoost.

Langkah-langkah analitis dilakukan sebagai berikut:

1. **Pengujian Stasioneritas**  
Data latih diuji menggunakan *Augmented Dickey-Fuller* (ADF) dan *Kwiatkowski-Phillips-Schmidt-Shin* (KPSS) untuk stasioneritas rata-rata, serta *ARCH-Lagrange Multiplier* (ARCH-LM) untuk stasioneritas varians. Pembedaan (*differencing*) dilakukan jika data terbukti tidak stasioner.
2. **Pemodelan ARIMAX (Linear)**  
Identifikasi ordo  $p$  dan  $q$  dievaluasi berdasarkan plot ACF dan PACF. Estimasi parameter model linear beserta variabel *dummy* dilakukan menggunakan metode *Maximum Likelihood Estimation* (MLE) [11]. Pemilihan model terbaik didasarkan pada nilai *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC) terendah yang merepresentasikan prinsip *parsimony*. Sisaan model linear ( $e_t$ ) diekstraksi dan divalidasi melalui uji Ljung-Box, Jarque-Bera, dan ARCH-LM untuk memastikan kelayakan.
3. **Pemodelan XGBoost (Non-Linear)**  
Jika sisaan model ARIMAX terbukti mengandung informasi (misalnya: gagal uji normalitas), algoritma XGBoost diterapkan. Karena XGBoost adalah algoritma *supervised learning*, data sisaan direkayasa menggunakan *sliding window* dengan 12 fitur *lag* ke belakang ( $e_{t-1}, e_{t-2}, \dots, e_{t-12}$ )

sebagai prediktor untuk memprediksi residu saat ini ( $e_t$ ). Optimalisasi *hyperparameter* (*learning rate, max depth, n estimators*) dilakukan melalui teknik *Grid Search Cross-Validation*.

### Metrik Evaluasi

Kinerja prediktif diukur dengan membandingkan prediksi akhir model ARIMAX tunggal dan model *Hybrid* terhadap data uji aktual. Tingkat akurasi diukur menggunakan *Root Mean Square Error* (RMSE) untuk mengevaluasi sensitivitas model terhadap *outlier*, dan *Mean Absolute Percentage Error* (MAPE) untuk interpretasi kesalahan relatif [12], [13].

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (4)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\% \quad (5)$$

Dimana,

$Y_t$  : Nilai aktual.

$\hat{Y}_t$  : Nilai prediksi.

$n$  : Jumlah observasi.

## Hasil dan Pembahasan

### Stasioneritas dan Pemodelan Linear ARIMAX

Tahap pra-pemrosesan menunjukkan bahwa data mobilitas penumpang memiliki volatilitas ekstrem akibat guncangan struktural pandemi. Pengujian akar unit melalui *Augmented Dickey-Fuller* (ADF) mengonfirmasi bahwa data tidak stasioner pada tingkat level. Stasioneritas rata-rata dan varians baru tercapai setelah dilakukan pembedaan pertama atau *first difference* ( $d = 1$ ).

Berdasarkan iterasi *Grid Search* menggunakan kriteria informasi, model ARIMAX(0,1,3) terpilih sebagai spesifikasi linear terbaik dengan nilai evaluasi *Akaike Information Criterion* (AIC) terendah sebesar 1461,22 dan *Bayesian Information Criterion* (BIC) sebesar 1480,18. Persamaan matematis model linear tersebut dinyatakan sebagai:

$$\nabla Y_t = \mu + \sum_{i=1}^4 \beta_i X_{i,t} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \theta_3 a_{t-3} \quad (6)$$

Estimasi parameter menunjukkan bahwa variabel intervensi terkait pandemi (*Dummy* Era Covid dan Pembatasan Ketat) terbukti sangat signifikan ( $p < 0,05$ ) dalam menekan jumlah penumpang. Variabel musiman tetap dipertahankan untuk memelihara justifikasi teoretis terhadap siklus natural transportasi.

### Diagnostik Sisaan

Kelayakan model linear dievaluasi melalui uji diagnostik sisaan (*residual*) [15]. Hasil uji Ljung-Box ( $p = 0,983$ ) dan ARCH-LM ( $p = 0,979$ ) mengonfirmasi bahwa sisaan model ARIMAX(0,1,3) telah bebas dari autokorelasi dan memiliki varians yang stabil. Namun, temuan krusial terjadi pada uji Jarque-Bera yang menolak hipotesis normalitas secara mutlak ( $p < 0,001$ ) dengan tingkat kurtosis ekstrem sebesar 5,63 [14].

Ketidaknormalan distribusi ini merupakan bukti empiris yang tak terbantahkan bahwa intervensi *dummy* linier memiliki keterbatasan inheren. Sisaan model masih mengandung struktur non-linear dan kompleksitas *outlier* yang gagal diproses oleh ARIMAX. Kegagalan asumsi klasik ini menjadi justifikasi mutlak urgensi implementasi algoritma XGBoost pada tahap pemodelan residu.

### Integrasi XGBoost dan Evaluasi Performa


Algoritma XGBoost dilatih menggunakan sisaan model ARIMAX dengan input 12 *lag* ke belakang (*sliding window*). Melalui *Grid Search Cross-Validation*, konfigurasi *hyperparameter* optimal dicapai pada arsitektur pohon dangkal (*max\_depth* = 3), *learning rate* konservatif 0,01, dan 100 estimator. Pemilihan struktur pohon dangkal ini sangat krusial secara metodologis untuk mencegah model terjebak dalam *overfitting* saat memproses sisaan yang sarat akan *noise* [13].

Perbandingan performa prediktif (*out-of-sample*) antara model tunggal dan hibrida diukur untuk memvalidasi efektivitas pendekatan yang diusulkan.

**Tabel 2** Perbandingan Kinerja Peramalan Model Tunggal vs. *Hybrid*.

| Model                 | Dataset                 | RMSE    | MAPE   |
|-----------------------|-------------------------|---------|--------|
| ARIMAX (0,1,3)        | Training (In-Sample)    | 4079,42 | 10,79% |
|                       | Testing (Out-of-Sample) | 8895,96 | 19,92% |
| Hybrid ARIMAX-XGBoost | Training (In-Sample)    | 2835,25 | 9,35%  |
|                       | Testing (Out-of-Sample) | 8650,60 | 19,36% |

Berdasarkan Tabel 2, pendekatan hibrida secara konsisten mengungguli model parametrik tunggal. Pada data uji, XGBoost berhasil memberikan koreksi dinamis yang menurunkan tingkat kesalahan absolut (RMSE) sebesar 2,76% menjadi 8650,60. Perbaikan *Mean Absolute Percentage Error* (MAPE) menjadi 19,36% menempatkan model *hybrid* ke dalam kategori kemampuan peramalan "Baik", sementara model linear murni tertinggal di ambang batas risiko (*under-forecasting* atau *over-forecasting*)



**Gambar 2.** Visualisasi Perbandingan Prediksi Aktual, ARIMAX, dan *Hybrid* pada Data Uji.

### Proyeksi Dinamika Mobilitas Masa Depan

Evaluasi visual pada pengujian *out-of-sample* (Gambar 2) memperlihatkan bahwa prediksi model masih tertinggal di bawah pergerakan data aktual (terjadi *under-forecasting* di kisaran 32.500 hingga 35.000 berbanding aktual 40.000 hingga 45.000). Hal ini mengindikasikan bahwa model membutuhkan waktu adaptasi terhadap akselerasi tren pemulihan pasca-pandemi yang sangat agresif, yang mana pola level ekstrem tersebut belum sepenuhnya terekam dalam periode data latih. Oleh karena itu, untuk memproyeksikan dinamika mobilitas masa depan yang realistis, model *hybrid* final diestimasi ulang (*retrained*) menggunakan keseluruhan dataset historis hingga Agustus 2025 agar memori informasi menyesuaikan dengan level ekuilibrium terbaru. Hasil peramalan prospektif (*forecasting*) dari model yang telah menyerap informasi level terbaru ini untuk periode September 2025 hingga Desember 2026 menunjukkan ekuilibrium baru (*steady state*). Volume penumpang diproyeksikan stabil pada kisaran 45.000 hingga 48.000 per bulan, dengan puncak musiman (*peak season*) tertinggi terdeteksi pada Juli 2026 (48.312 penumpang) akibat aktivasi intervensi kalender akademik.

## Kesimpulan

Berdasarkan hasil analisis, model parametrik ARIMAX(0,1,3) dengan integrasi variabel *dummy* intervensi terbukti tangguh dalam mengkuantifikasi dampak makro dari guncangan struktural COVID-19 dan memulihkan pola musiman yang sempat terdistorsi. Namun, model linear ini menunjukkan keterbatasan fundamental dalam menangkap volatilitas mikro, yang dibuktikan secara empiris oleh sisaan (*residuals*) yang tidak berdistribusi normal dan memiliki kurtosis ekstrem. Implementasi *eXtreme Gradient Boosting* (XGBoost) pada tahap kedua pemodelan terbukti mutlak diperlukan untuk menyelesaikan defisiensi tersebut. Pendekatan hibrida ARIMAX-XGBoost mampu mengungguli model tunggal dengan menurunkan tingkat kesalahan (RMSE) sebesar 2,76% dan memperbaiki akurasi (MAPE) sebesar 2,81% pada pengujian *out-of-sample*. Meskipun perbaikan akurasi ini tergolong inkremental (*marginal*), integrasi XGBoost tetap terbukti efektif beroperasi sebagai korektor minor untuk menyerap pola volatilitas mikro pada sisaan model linear. Penggunaan arsitektur hibrida ini perlu dipertimbangkan secara strategis terhadap *trade-off* penambahan kompleksitas komputasinya, sehingga pendekatannya lebih tepat diposisikan sebagai langkah optimasi lanjutan (*fine-tuning*) dalam merespons dinamika pemulihan pasca-pandemi.

Secara praktis, hasil peramalan prospektif mengindikasikan bahwa volume penumpang kereta api nasional pada 2025-2026 telah mencapai ekuilibrium baru (*steady state*) di kisaran 45.000 hingga 48.000 penumpang per bulan. PT Kereta Api Indonesia direkomendasikan untuk mengoptimalkan alokasi armada secara masif pada puncak musiman (Juli dan Desember) berbasis proyeksi ini. Namun, manajemen tidak boleh terlena pada stabilitas angka tersebut, pemantauan ketat wajib dilakukan terhadap potensi kanibalisasi permintaan akibat disrupsi moda transportasi kompetitor baru (seperti Kereta Cepat dan Tol Trans-Jawa) yang belum terekam dalam memori data historis.

Untuk pengembangan metodologis ke depan, arsitektur *Two-Stage Hybrid* ini direkomendasikan untuk diuji pada sektor lain yang rentan terhadap guncangan makro, seperti konsumsi energi atau pasar keuangan. Peneliti selanjutnya disarankan untuk memperluas ruang dimensi input dengan mengintegrasikan indikator makroekonomi (seperti PDB atau inflasi) sebagai regressor eksternal, serta menguji performa XGBoost melawan arsitektur jaringan saraf tiruan mutakhir seperti *Long Short-Term Memory* (LSTM) guna mengevaluasi batas maksimal optimasi residu deret waktu non-linear

## Referensi

- [1] A. Leliana, S. Ferlianne, and M. Muhandjito, "Optimalisasi jumlah perjalanan KRL lintas Jakarta Kota-Bogor terhadap demand penumpang menggunakan ARIMA Box-Jenkins," *Journal of Sustainable Civil Engineering (JOSCE)*, vol. 5, no. 1, 2023.

- [2] K. Sugiono and M. Herlina, "Analisis fuzzy time series pada jumlah penumpang kereta api di wilayah Sumatera menggunakan metode Markov chain dan Lee," *Bandung Conference Series: Statistics*, vol. 4, no. 1, pp. 291-301, 2024.
- [3] Y. Angraini, A. Pangestika, and I. Sumertajaya, "Comparison of the symmetric and asymmetric generalized autoregressive conditional heteroscedasticity (GARCH) models in forecasting the 2018-2023 Jakarta Composite Index," *ComTech*, vol. 15, no. 1, pp. 1-15, 2024.
- [4] M. Arumsari and A. Dani, "Peramalan data runtun waktu menggunakan model hybrid time series regression autoregressive integrated moving average," *Jurnal Siger Matematika*, vol. 2, no. 1, 2021.
- [5] W. W. S. Wei, *Time series analysis: Univariate and multivariate methods*, 2nd ed. Pearson Education, 2006.
- [6] A. Hadianfar, R. Yousefi, M. Delavary, V. Fakoore, M. Shakeri, and M. Lavallière, "Effects of government policies and the Nowruz holidays on confirmed COVID-19 cases in Iran: An intervention time series analysis," *PLOS One*, vol. 16, no. 8, p. e0256516, 2021.
- [7] L. Huang, X. Zhao, Y. Liu, and P. Yang, "Analysis of the atmospheric duct existence factors in tropical cyclones based on the SHAP interpretation of extreme gradient boosting predictions," *Remote Sensing*, vol. 14, no. 16, p. 3952, 2022.
- [8] S. Odhiambo, N. Cornelious, and H. Waititu, "Developing a hybrid ARIMA-XGBoost model for analysing mobile money transaction data in Kenya," *Asian Journal of Probability and Statistics*, vol. 26, no. 10, pp. 108-126, 2024.
- [9] Badan Pusat Statistik, "Penumpang Angkutan Kereta Api Nasional Bulanan," Badan Pusat Statistik. [Daring]. Tersedia: <https://www.bps.go.id/id/statistics-table/2/MjM1MyMy/penumpang-angkutan-kereta-api-nasional-bulanan-.html> (Diakses: 24 September 2025).
- [10] V. R. Joseph, "Optimal ratio for data splitting," *Statistical Analysis and Data Mining: The ASA Data Science Journal*, vol. 15, no. 4, pp. 531-538, 2022.
- [11] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time series analysis: Forecasting and control*, 5th ed. John Wiley & Sons, 2015.
- [12] I. Benitez, J. Ibañez, C. Lumabad, J. Cañete, and J. Principe, "Day-ahead hourly solar photovoltaic output forecasting using SARIMAX, long short-term memory, and extreme gradient boosting: Case of the Philippines," *Energies*, vol. 16, no. 23, p. 7823, 2023.
- [13] K. Sivhugwana and E. Ranganai, "An ensemble approach to short-term wind speed predictions using stochastic methods, wavelets and gradient boosting decision trees," *Wind*, vol. 4, no. 1, pp. 44-67, 2024.
- [14] H. Hassani, M. Royer-Carenzi, L. Mashhad, M. Yarmohammadi, and M. Yeganegi, "Exploring the depths of the autocorrelation function: Its departure from normality," *Information*, vol. 15, no. 8, p. 449, 2024.
- [15] N. Al-Saati, I. Omran, A. Al-Taai, Z. Al-Saati, and K. Hashim, "Statistical modeling of monthly streamflow using time series and artificial neural network models: Hindiya barrage as a case study," *Water Practice & Technology*, vol. 16, no. 2, pp. 681-691, 2021.