

Forecasting Volume Penumpang Harian KRL Yogyakarta–Solo Menggunakan SARIMA, LSTM, dan SARIMA-LSTM

Marta Ardiyanto^{1*}, Ridwan Dwi Irawan², Esti Dwi Rahmawati³

¹ Fakultas Ilmu Komputer, S1 Sistem Informasi, Universitas Duta Bangsa, Surakarta, Indonesia

² Fakultas Ilmu Komputer, D4 Teknologi Rekayasa Perangkat Lunak, Universitas Duta Bangsa, Surakarta, Indonesia

³ Fakultas Hukum Bisnis, S1 Manajemen, Universitas Duta Bangsa, Surakarta, Indonesia

Email: ¹marta.ardiyanto@udb.ac.id, ²ridwan_dwiirawan@udb.ac.id, ³esti_dwirahmawati@udb.ac.id

Email Penulis Korespondensi: marta.ardiyanto@udb.ac.id

Submitted 13-05-2026; Accepted 04-06-2026; Published 30-06-2026

Abstrak

Forecasting volume penumpang transportasi publik penting untuk mendukung pengambilan keputusan operasional berbasis data. KRL Yogyakarta–Solo sebagai moda transportasi strategis memiliki pola jumlah penumpang yang fluktuatif akibat pengaruh hari kerja, akhir pekan, hari libur nasional, dan cuti bersama. Kondisi tersebut membutuhkan model *forecasting* yang mampu menangkap pola musiman dan perubahan nonlinier pada data deret waktu. Penelitian ini bertujuan membandingkan performa *Seasonal Autoregressive Integrated Moving Average* (SARIMA), *Long Short-Term Memory* (LSTM), dan *hibrida SARIMA-LSTM* dalam *forecasting* volume penumpang harian KRL Yogyakarta–Solo. Kontribusi utama penelitian ini adalah evaluasi komparatif tiga pendekatan *forecasting* pada data harian KRL berbasis fitur kalender, sekaligus menunjukkan bahwa pendekatan hibrida berbasis residual tidak selalu menghasilkan performa terbaik pada dataset dengan karakteristik tertentu. Dataset yang digunakan adalah data volume penumpang harian KRL periode Januari–Desember 2025. Tahapan penelitian meliputi *preprocessing*, *feature engineering* berbasis kalender, pembagian data *training* dan *testing* secara kronologis, pemodelan SARIMA, LSTM, hibrida SARIMA-LSTM, serta evaluasi menggunakan MAE, RMSE, dan MAPE. Hasil penelitian menunjukkan bahwa SARIMA memperoleh MAE 2644,81, RMSE 3299,78, dan MAPE 10,56%. LSTM menghasilkan MAE 1977,50, RMSE 2528,75, dan MAPE 7,28%. Sementara itu, hibrida SARIMA-LSTM memperoleh MAE 2634,78, RMSE 3294,24, dan MAPE 10,52%. Berdasarkan hasil tersebut, LSTM memberikan performa *forecasting* terbaik dibandingkan SARIMA dan hibrida SARIMA-LSTM. Temuan ini menunjukkan bahwa pemilihan model *forecasting* perlu mempertimbangkan karakteristik data, pola residual, dan kecukupan data historis. Penelitian selanjutnya disarankan menggunakan data historis yang lebih panjang serta menambahkan variabel eksternal untuk meningkatkan akurasi *forecasting*.

Kata Kunci: *Forecasting*; KRL Yogyakarta–Solo; SARIMA; LSTM; SARIMA-LSTM; *Time Series*;

Abstract

Passenger volume *forecasting* in public transportation is an important aspect of supporting data-driven operational decision-making. The Yogyakarta–Solo Commuter Rail is a strategic public transportation mode that supports interregional mobility. Fluctuations in passenger volume influenced by daily patterns, weekends, national holidays, and collective leave periods require *forecasting* models capable of capturing seasonal patterns and possible nonlinear changes in time series data. This study aims to compare the performance of Seasonal Autoregressive Integrated Moving Average (SARIMA), Long Short-Term Memory (LSTM), and hybrid SARIMA-LSTM models in *forecasting* the daily passenger volume of the Yogyakarta–Solo Commuter Rail. The dataset consists of daily passenger volume data from January to December 2025. The research stages include data preprocessing, calendar-based feature engineering, chronological training and testing data splitting, SARIMA modeling, LSTM modeling, residual modeling using LSTM, and performance evaluation using MAE, RMSE, and MAPE. The results show that the SARIMA model obtained an MAE of 2644.81, an RMSE of 3299.78, and a MAPE of 10.56%. The LSTM model obtained an MAE of 1977.50, an RMSE of 2528.75, and a MAPE of 7.28%. Meanwhile, the hybrid SARIMA-LSTM model achieved an MAE of 2634.78, an RMSE of 3294.24, and a MAPE of 10.52%. Based on these results, the LSTM model achieved the best *forecasting* performance compared to SARIMA and hybrid SARIMA-LSTM. The hybrid SARIMA-LSTM model provided only a slight improvement over SARIMA but did not outperform the LSTM model. These findings indicate that *forecasting* model selection should consider dataset characteristics, residual patterns, and the adequacy of historical data. Future research is recommended to use longer historical data and incorporate relevant external variables to improve *forecasting* accuracy.

Keywords: *Forecasting*; Yogyakarta–Solo Commuter Rail; SARIMA; LSTM; SARIMA-LSTM; *Time Series*;

1. PENDAHULUAN

Volume penumpang transportasi publik cenderung mengalami fluktuasi dari waktu ke waktu, terutama pada layanan yang melayani mobilitas harian masyarakat antarwilayah. Fluktuasi tersebut dapat dipengaruhi oleh aktivitas kerja, pendidikan, akhir pekan, hari libur nasional, cuti bersama, serta peningkatan perjalanan pada periode tertentu. Pada layanan KRL Yogyakarta–Solo, perubahan jumlah penumpang yang tidak terantisipasi berpotensi menimbulkan kepadatan di stasiun, ketidaksesuaian kapasitas armada, penumpukan penumpang pada jam tertentu, serta kebutuhan penyesuaian jadwal perjalanan.

Kondisi tersebut menunjukkan bahwa pengelolaan transportasi publik tidak cukup hanya mengandalkan analisis deskriptif terhadap data historis. Diperlukan pendekatan analitis yang mampu memperkirakan volume penumpang pada periode mendatang secara lebih akurat. Oleh karena itu, *forecasting* volume penumpang menjadi penting sebagai dasar pengambilan keputusan operasional berbasis data, khususnya dalam mendukung perencanaan kapasitas, pengaturan jadwal, dan peningkatan kualitas layanan.

Sejalan dengan agenda transformasi digital pada sektor transportasi publik, pemanfaatan kecerdasan buatan, *machine learning*, dan analisis prediktif menjadi semakin relevan dalam mendukung sistem transportasi yang adaptif dan efisien

[1]. *Forecasting* berbasis data deret waktu dapat membantu penyedia layanan dalam memahami pola historis, mengenali tren musiman, serta mengantisipasi lonjakan penumpang yang dipengaruhi oleh pola kalender. Dalam konteks KRL Yogyakarta–Solo yang dikelola oleh PT Kereta Commuter Indonesia, kebutuhan *forecasting* menjadi penting karena jalur ini mendukung mobilitas pekerja komuter, mahasiswa, wisatawan, dan masyarakat umum pada koridor Yogyakarta–Solo [2].

Peningkatan jumlah penumpang di sisi lain menimbulkan berbagai tantangan operasional, seperti kepadatan pada jam sibuk, lonjakan penumpang pada masa liburan, serta kebutuhan pengaturan jadwal perjalanan yang lebih adaptif. Ketidakakuratan dalam memprediksi volume penumpang dapat menyebabkan ketidakefisienan operasional, penurunan kualitas layanan, dan ketidaksesuaian kapasitas armada terhadap permintaan aktual. Oleh karena itu, dibutuhkan model *forecasting* yang mampu menghasilkan prediksi jumlah penumpang secara akurat untuk mendukung pengambilan keputusan operasional berbasis data.

Penelitian mengenai *forecasting* transportasi publik telah berkembang pesat dalam beberapa tahun terakhir. Kajian sistematis yang dilakukan oleh F. R. Di Torrepadula menyatakan bahwa pendekatan machine learning dan deep learning memiliki kemampuan tinggi dalam menangani kompleksitas data transportasi publik, khususnya pada pola nonlinier dan data berskala besar [3],[4],[5]. Dalam konteks prediksi berbasis *time series*, penelitian oleh S. Priyanto membandingkan metode *Gray* (1,1), *Moving Average*, dan *Exponential Smoothing* untuk memprediksi jumlah penumpang KRL Jogja–Solo [6]. Hasil penelitian menunjukkan bahwa metode statistik konvensional mampu menghasilkan prediksi yang cukup baik, namun masih memiliki keterbatasan dalam menangkap pola fluktuasi kompleks dan perubahan nonlinier pada data penumpang.

Perkembangan *deep learning* juga menunjukkan performa yang menjanjikan pada *forecasting* transportasi publik. Penelitian Y. Lu mengembangkan model prediksi arus penumpang berbasis *multi-scale decomposition* dan *deep attention mechanism* yang mampu meningkatkan akurasi prediksi pada sistem transportasi rel [7]. Penelitian lain oleh J. Sun menggunakan pendekatan *spatio-temporal feature fusion* untuk memprediksi *passenger flow multi-step* pada transportasi perkotaan dan menunjukkan peningkatan performa dalam menangani pola pergerakan penumpang antar stasiun [8]. Selain itu, pendekatan *forecasting* juga telah digunakan pada analisis permintaan wisatawan domestik [9], permintaan penumpang harian dan mingguan pada *urban rail transit* [10], *short-term traffic flow* pada sistem metro [11], serta kajian mobilitas wisata yang berkaitan dengan karakteristik pergerakan masyarakat pada destinasi wisata [12]. Penelitian G. Shi menunjukkan bahwa pola mobilitas penumpang pascapandemi mengalami perubahan signifikan sehingga diperlukan model prediksi yang lebih adaptif terhadap dinamika perilaku pengguna transportasi [13]. Shafique juga menekankan pentingnya *forecasting* tingkat okupansi kereta untuk mendukung peningkatan ridership dan kualitas layanan transportasi publik [14].

Di Indonesia, penelitian *forecasting* jumlah penumpang KRL masih didominasi pendekatan statistik tradisional seperti ARIMA dan metode *smoothing*. Fajarianto et al. menunjukkan bahwa metode ARIMA mampu menghasilkan performa *forecasting* yang cukup baik pada data penumpang KRL Jabodetabek [15]. Namun demikian, pendekatan tersebut masih memiliki keterbatasan dalam memodelkan pola nonlinier dan lonjakan penumpang yang dipengaruhi faktor eksternal seperti hari libur, aktivitas wisata, dan perubahan perilaku mobilitas masyarakat.

Dari sisi metodologis, normalisasi input pada data *time series* penting dilakukan untuk meningkatkan stabilitas proses pelatihan model *deep learning* [16]. Perbandingan ARIMA, SARIMA, dan LSTM dalam *forecasting* deret waktu menunjukkan bahwa model statistik dan deep learning memiliki karakteristik berbeda dalam menangkap pola linier, musiman, dan nonlinier [17]. Selain itu, *machine learning* juga telah digunakan dalam evaluasi performa transportasi publik [18], sedangkan pendekatan *forecasting* permintaan penumpang dapat mendukung optimasi *dispatching* dan pengambilan keputusan operasional pada sistem transportasi publik [19]. Penelitian terbaru juga menunjukkan bahwa pendekatan deep learning dan model hibrida semakin banyak digunakan dalam *forecasting passenger flow* karena mampu menangani dinamika temporal, pola nonlinier, serta fluktuasi permintaan transportasi publik yang kompleks [20], [21]. Selain itu, pendekatan hibrida berbasis SARIMA juga telah dikembangkan untuk *forecasting outbound subway passenger flow* dengan teknik dekomposisi [22].

Berdasarkan penelitian terdahulu, terdapat beberapa gap yang menjadi dasar penelitian ini. Pertama, studi *forecasting* pada KRL Jogja–Solo masih terbatas pada metode statistik konvensional dan belum banyak membandingkan pendekatan statistik musiman, *deep learning*, dan model hibrida dalam satu kerangka evaluasi. Kedua, penelitian sebelumnya belum secara spesifik menguji kemampuan model dalam menangkap pola volume penumpang harian yang dipengaruhi oleh fitur kalender, seperti akhir pekan, hari libur nasional, dan cuti bersama. Ketiga, kajian mengenai hibrida SARIMA-LSTM berbasis residual pada konteks volume penumpang harian KRL Yogyakarta–Solo masih terbatas, sehingga diperlukan evaluasi untuk mengetahui apakah kombinasi model statistik dan deep learning mampu memberikan peningkatan performa dibandingkan model tunggal.

Novelty penelitian ini terletak pada evaluasi komparatif tiga pendekatan *forecasting*, yaitu SARIMA, LSTM, dan hibrida SARIMA-LSTM, pada data harian volume penumpang KRL Yogyakarta–Solo dengan mempertimbangkan fitur kalender. SARIMA digunakan untuk merepresentasikan pola linier dan musiman, LSTM digunakan untuk menangkap pola nonlinier pada data deret waktu, sedangkan hibrida SARIMA-LSTM digunakan untuk memodelkan residual SARIMA melalui LSTM. Dengan demikian, penelitian ini tidak hanya membandingkan akurasi model, tetapi juga mengevaluasi sejauh mana pendekatan hibrida berbasis residual mampu meningkatkan performa *forecasting* pada dataset penumpang harian KRL.

Berdasarkan gap tersebut, penelitian ini bertujuan untuk membandingkan performa SARIMA, LSTM, dan hibrida SARIMA-LSTM dalam forecasting volume penumpang harian KRL Yogyakarta–Solo. Evaluasi performa dilakukan menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Kontribusi utama penelitian ini adalah memberikan bukti empiris mengenai model *forecasting* yang paling sesuai untuk data penumpang harian KRL Yogyakarta–Solo, serta menjadi dasar pengembangan sistem pendukung keputusan operasional transportasi publik berbasis data.

2. METODOLOGI PENELITIAN


2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan utama untuk membandingkan performa model SARIMA, LSTM, dan hibrida SARIMA-LSTM dalam forecasting volume penumpang harian KRL Yogyakarta–Solo. Tahapan penelitian meliputi pengumpulan data, *preprocessing data*, *feature engineering*, pembagian data, analisis pola *time series*, pemodelan SARIMA, pemodelan LSTM, pemodelan residual SARIMA menggunakan LSTM, pembentukan model hibrida SARIMA-LSTM, evaluasi performa, dan perbandingan hasil *forecasting*.

Tahap pertama adalah pengumpulan data volume penumpang harian KRL Yogyakarta–Solo periode Januari hingga Desember 2025. Data utama yang digunakan adalah jumlah penumpang harian pada koridor KRL Area VI Yogyakarta. Selain itu, penelitian ini juga memanfaatkan informasi berbasis kalender, seperti hari dalam minggu, akhir pekan, hari libur nasional, dan cuti bersama untuk mendukung analisis pola fluktuasi penumpang. Tahap *preprocessing* dilakukan untuk memastikan dataset memiliki format yang bersih dan konsisten sebelum digunakan dalam proses pemodelan. Proses ini meliputi pemeriksaan data duplikat, penanganan missing value, konversi atribut tanggal ke format *datetime*, serta konversi jumlah penumpang ke format numerik. Selanjutnya dilakukan *feature engineering* dengan menambahkan atribut turunan berupa nama hari, status akhir pekan, status hari libur nasional, dan status cuti bersama.

Dataset yang telah diproses kemudian dibagi menjadi data training dan data testing dengan komposisi 80:20 secara kronologis. Pembagian secara kronologis dilakukan karena data yang digunakan merupakan data *time series*, sehingga urutan waktu harus dipertahankan dan tidak dilakukan pengacakan data. Setelah itu, dilakukan analisis pola *time series* melalui visualisasi data, serta analisis ACF dan PACF untuk membantu menentukan parameter awal model SARIMA dan periode musiman. Pemodelan dilakukan dalam dua tahap. Pertama, model SARIMA digunakan sebagai *baseline forecasting* untuk menangkap pola linier dan musiman pada data penumpang. Parameter model dipilih dengan mempertimbangkan hasil ACF, PACF, dan nilai AIC. Model SARIMA kemudian menghasilkan nilai *forecasting* awal dan *residual error*.

Tahap berikutnya adalah pemodelan residual menggunakan *Long Short-Term Memory* (LSTM). *Residual error* dari SARIMA digunakan sebagai input LSTM untuk mempelajari kemungkinan pola nonlinier yang belum dapat ditangkap oleh SARIMA. Sebelum proses pelatihan, residual dinormalisasi menggunakan *MinMaxScaler* dan dibentuk menjadi *sequence* menggunakan pendekatan *sliding window*. Hasil *forecasting* akhir model hibrida diperoleh dengan menjumlahkan hasil *forecasting* SARIMA dan hasil koreksi residual dari LSTM. Tahap terakhir adalah evaluasi dan perbandingan performa model. Evaluasi dilakukan menggunakan *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Selain evaluasi numerik, visualisasi perbandingan antara data aktual dan hasil *forecasting* digunakan untuk melihat kemampuan model dalam mengikuti pola perubahan volume penumpang secara temporal.



Gambar 1. Tahapan Penelitian *Forecasting* Volume Penumpang KRL Yogyakarta–Solo

2.2 Dataset Penelitian

Dataset yang digunakan dalam penelitian ini merupakan data deret waktu (time series) volume penumpang harian KRL Yogyakarta–Solo yang diperoleh dari portal keterbukaan informasi PT Kereta Commuter Indonesia. Data yang digunakan mencakup periode Januari 2025 hingga Desember 2025 dengan resolusi harian. Dataset terdiri dari informasi jumlah penumpang pada koridor KRL Area VI Yogyakarta yang digunakan untuk menganalisis pola mobilitas masyarakat dan fluktuasi jumlah penumpang dari waktu ke waktu.

Selain data historis operasional KRL, penelitian ini juga menggunakan variabel eksternal berbasis kalender nasional untuk membantu model mengenali pola lonjakan penumpang yang bersifat non-rutin. Variabel eksternal tersebut meliputi status hari kerja, akhir pekan, hari libur nasional, dan cuti bersama. Penggunaan variabel eksternal dilakukan karena pola mobilitas penumpang KRL dipengaruhi oleh aktivitas komuter harian maupun peningkatan perjalanan masyarakat pada periode libur tertentu.

Secara umum, atribut yang digunakan dalam penelitian meliputi Tanggal operasional, Jumlah penumpang harian, Hari dalam minggu, Status akhir pekan, Status hari libur nasional, Status cuti bersama

Tabel 1. Deskripsi Variabel Penelitian

Variabel	Tipe Data	Keterangan
Tanggal Operasional	Date	Tanggal pelaksanaan operasional KRL harian
Jumlah Penumpang Harian	Numerik	Total penumpang KRL per hari
Hari dalam Minggu	Kategorikal	Informasi nama hari berdasarkan tanggal
Status Akhir Pekan	Biner	Penanda hari Sabtu/Minggu
Status Hari Libur Nasional	Biner	Penanda hari libur nasional
Status Cuti Bersama	Biner	Penanda periode cuti bersama

Sebelum digunakan pada tahap pemodelan, seluruh dataset melalui proses preprocessing untuk memastikan kualitas dan konsistensi data. Tahapan preprocessing meliputi pembersihan data (*data cleaning*), penanganan missing value, transformasi format numerik, konversi atribut tanggal ke format datetime, serta normalisasi data untuk kebutuhan model *deep learning*.

Dataset kemudian dibagi menjadi dua bagian, yaitu data pelatihan (*training set*) sebesar 80% dan data pengujian (*testing set*) sebesar 20%. Pembagian dilakukan secara kronologis untuk menjaga karakteristik data deret waktu dan menghindari terjadinya data leakage pada proses pelatihan model.

2.3 Preprocessing Data

Tahap pra-pemrosesan data dilakukan untuk memastikan bahwa dataset berada dalam kondisi bersih, konsisten, dan siap digunakan pada proses pelatihan model *forecasting*. *Preprocessing* diperlukan dalam analisis deret waktu karena normalisasi dan konsistensi input dapat meningkatkan performa model *forecasting* [16]. Proses pra-pemrosesan diawali dengan pemeriksaan data duplikat, pengecekan konsistensi format numerik, serta identifikasi *missing value* pada setiap atribut dataset. Nilai yang hilang ditangani menggunakan metode imputasi yang disesuaikan dengan karakteristik data agar tidak mengganggu pola distribusi deret waktu. Selanjutnya dilakukan konversi atribut tanggal ke format *datetime* untuk mendukung analisis *time series* dan proses ekstraksi fitur temporal.

Pada tahap berikutnya dilakukan rekayasa fitur (*feature engineering*) dengan menambahkan beberapa atribut turunan berbasis waktu, seperti hari dalam minggu, status akhir pekan, status hari libur nasional, dan status cuti bersama. Penambahan fitur tersebut bertujuan untuk membantu model dalam mengenali pola perubahan jumlah penumpang yang dipengaruhi oleh aktivitas mobilitas masyarakat pada periode tertentu. Normalisasi data dilakukan menggunakan *MinMaxScaler* pada data yang digunakan sebagai input model LSTM, baik pada model LSTM tunggal maupun pada pemodelan residual SARIMA-LSTM. Rumus normalisasi *MinMaxScaler* dinyatakan sebagai berikut:

$$X_{\text{Scaled}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

dengan (X_{Scaled}) merupakan nilai hasil normalisasi, (x) merupakan nilai data asli, ($x_{\min}$) merupakan nilai minimum pada data training, dan ($x_{\max}$) merupakan nilai maksimum pada data training. Normalisasi dilakukan karena model *deep learning*, termasuk LSTM, sensitif terhadap perbedaan skala data sehingga proses pelatihan menjadi lebih stabil [16].

Setelah proses normalisasi selesai, data dibentuk menjadi *sequence* menggunakan pendekatan *sliding window*. Pada penelitian ini, *window size* ditetapkan sebesar 7 untuk merepresentasikan pola mingguan pada data penumpang harian. Dengan demikian, model menggunakan tujuh data historis sebelumnya untuk mempelajari pola dan menghasilkan *forecasting* pada periode berikutnya. Dataset yang telah diproses kemudian dibagi menjadi data training sebesar 80% dan data testing sebesar 20% secara kronologis untuk menjaga karakteristik data deret waktu dan menghindari data leakage selama proses pelatihan model.

2.4 Arsitektur Model Forecasting

Penelitian ini menggunakan tiga pendekatan model *forecasting*, yaitu SARIMA, LSTM, dan hibrida SARIMA-LSTM. SARIMA digunakan sebagai baseline statistik untuk menangkap pola linier dan musiman pada data deret waktu. LSTM digunakan sebagai model *deep learning* untuk mempelajari pola historis dan kemungkinan pola nonlinier secara langsung. Sementara itu, hibrida SARIMA-LSTM digunakan untuk memodelkan *residual error* SARIMA dengan LSTM. Penggunaan model statistik dan *deep learning* dalam *forecasting* deret waktu banyak digunakan karena keduanya memiliki karakteristik yang berbeda dalam menangkap pola linier, musiman, dan nonlinier pada data [17], [20], [22]. Tahap awal penelitian dilakukan dengan membangun model SARIMA sebagai baseline *forecasting*. Model SARIMA merupakan pengembangan dari ARIMA yang menambahkan komponen musiman untuk memodelkan data deret waktu yang memiliki pola berulang dalam periode tertentu. SARIMA umum digunakan pada data deret waktu musiman karena mampu merepresentasikan komponen *autoregressive*, *differencing*, *moving average*, serta komponen musiman secara simultan [17]. Bentuk umum model SARIMA dinyatakan sebagai berikut:

$$\text{SARIMA}(p,d,q)(P,D,Q)_s \quad (2)$$

Persamaan umum model SARIMA dapat direpresentasikan sebagai berikut:

$$\Phi_p(L^s)\phi_p(L)(1-L)^d(1-L^s)^D y_t = \theta_q(L^s)\theta_q(L)\varepsilon_t \quad (3)$$

Penjelasan Komponen:

y_t : Nilai variabel pada waktu ke- t (prediksi akhir).

L : *Lag operator* ($Ly_t = y_{t-1}$)

$\Phi_p(L)$ & $\phi_q(L)$: Komponen Non-musiman (*Autoregressive* dan *Moving Average*).

$\Phi_p(L^s)$ & $\phi_q(L^s)$: Komponen Musiman (*Seasonal AR* dan *Seasonal MA*).

$\Delta^d \Delta_s^D$: Proses *differencing* non-musiman dan musiman untuk membuat data menjadi stasioner.

ε_t : *White noise* atau nilai kesalahan (error) pada waktu t .

S : Periode musiman (misal: $S=12$ untuk data bulanan dengan siklus tahunan).


Setelah model SARIMA dibangun, dilakukan proses *forecasting* untuk menghasilkan nilai prediksi awal beserta *residual error*. *Residual error* merupakan selisih antara data aktual dan hasil prediksi SARIMA yang masih mengandung pola nonlinier. *Residual* tersebut kemudian digunakan sebagai input pada model *Long Short-Term Memory* (LSTM).

LSTM merupakan pengembangan dari *Recurrent Neural Network* (RNN) yang dirancang untuk menangani data *sequential* dan dependensi jangka panjang melalui mekanisme *memory cell* dan *gate system*. Pada penelitian ini, model LSTM digunakan untuk mempelajari pola *residual error* hasil prediksi SARIMA sehingga mampu melakukan koreksi terhadap kesalahan prediksi sebelumnya. Sebelum proses pelatihan dilakukan, data *residual* dinormalisasi menggunakan *MinMaxScaler* dan dibentuk menjadi *sequence* menggunakan pendekatan *sliding window*.

Arsitektur hybrid SARIMA-LSTM pada penelitian ini terdiri dari dua tahapan utama. Tahap pertama adalah *forecasting* menggunakan model SARIMA untuk menangkap pola linier dan musiman pada data penumpang. Tahap kedua adalah pemodelan residual menggunakan LSTM untuk menangkap pola nonlinier yang masih tersisa.

$$\hat{y}_t^{Hybrid} = \hat{y}_t^{SARIMA} + \hat{e}_t^{LSTM} \quad (4)$$

Hasil akhir *forecasting* diperoleh melalui kombinasi output prediksi SARIMA dan output koreksi residual dari model LSTM.



Gambar 2. Arsitektur Hybrid SARIMA-LSTM

2.5 Metode Evaluasi

Evaluasi performa model dilakukan untuk mengukur tingkat akurasi *forecasting* volume penumpang KRL Yogyakarta–Solo. Pada penelitian ini digunakan tiga metrik evaluasi utama, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Ketiga metrik tersebut digunakan untuk membandingkan performa model SARIMA, LSTM, dan hibrida SARIMA-LSTM terhadap data aktual[17].

1. Mean Absolute Error (MAE)

MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan hasil prediksi. Rumus MAE dinyatakan sebagai berikut:

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

2. Root Mean Square Error (RMSE)

RMSE digunakan untuk mengukur tingkat error dengan memberikan penalti lebih besar terhadap error yang tinggi. Rumus RMSE dinyatakan sebagai berikut:

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

3. Mean Absolute Percentage Error (MAPE)

MAPE digunakan untuk mengukur tingkat kesalahan prediksi dalam bentuk persentase. Rumus MAPE dinyatakan sebagai berikut:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (7)$$


Model terbaik dipilih berdasarkan nilai MAE, RMSE, dan MAPE terkecil serta kestabilan hasil *forecasting* terhadap data aktual. Selain evaluasi numerik, penelitian ini juga menggunakan visualisasi perbandingan antara data aktual dan hasil *forecasting* untuk melihat kemampuan model dalam mengikuti pola perubahan volume penumpang secara temporal.

2.6 Experimental Setup

Eksperimen dilakukan dengan membandingkan tiga model, yaitu SARIMA sebagai *baseline* statistik, LSTM sebagai model *deep learning*, dan hibrida SARIMA-LSTM sebagai model usulan berbasis residual. Seluruh proses pelatihan dan pengujian dilakukan menggunakan skema pembagian data secara kronologis, yaitu 80% data awal sebagai data *training* dan 20% data terakhir sebagai data *testing*. Skema ini digunakan untuk menjaga karakteristik *time series* dan menghindari terjadinya data *leakage*. Pada model SARIMA, penentuan parameter dilakukan melalui analisis *Auto Correlation Function* (ACF), *Partial Auto Correlation Function* (PACF), serta evaluasi nilai *Akaike Information Criterion* (AIC). Periode musiman ditetapkan sebesar 7 karena data penumpang harian menunjukkan pola mingguan. Berdasarkan hasil analisis dan evaluasi AIC, model yang digunakan adalah SARIMA(2,1,2)(1,1,1)₇.

Pada model LSTM, data historis volume penumpang dinormalisasi menggunakan *MinMaxScaler* dan dibentuk menjadi *sequence* menggunakan *sliding window* dengan *window size* sebesar 7. Model LSTM dilatih menggunakan data *training* dan diuji pada data *testing* yang sama dengan model SARIMA dan hibrida SARIMA-LSTM. Konfigurasi pelatihan LSTM menggunakan optimizer Adam, *loss function* *Mean Squared Error*, *epoch* 100, dan *batch size* 16.

Pada model hibrida SARIMA-LSTM, *Residual error* dinormalisasi menggunakan *MinMaxScaler*, kemudian dibentuk menjadi *sequence* dengan pendekatan *sliding window*. Model LSTM dilatih untuk mempelajari pola residual yang belum dapat ditangkap oleh SARIMA. Hasil *forecasting* akhir diperoleh dengan menjumlahkan hasil *forecasting* SARIMA dan hasil *forecasting residual* dari LSTM. Skema *experimental setup* yang digunakan ditunjukkan pada Gambar 3.




Gambar 3. Skema *Experimental Setup* Model SARIMA, LSTM, dan Hibrida SARIMA-LSTM

3. HASIL DAN PEMBAHASAN

3.1. Analisis Data Penumpang KRL Yogyakarta–Solo


Pada tahap awal penelitian dilakukan analisis eksploratif terhadap data historis volume penumpang KRL Yogyakarta–Solo untuk mengidentifikasi karakteristik data deret waktu, seperti pola tren, pola musiman, dan fluktuasi jumlah penumpang dari waktu ke waktu. Analisis ini bertujuan untuk memahami pola dasar data sebelum dilakukan proses pemodelan *forecasting* menggunakan SARIMA dan hybrid SARIMA-LSTM.

Berdasarkan visualisasi rata-rata volume penumpang berdasarkan hari dalam minggu, terlihat adanya perbedaan jumlah penumpang antahari. Perbedaan tersebut mengindikasikan adanya pola musiman mingguan pada data penumpang harian KRL Yogyakarta–Solo. Pola ini dapat berkaitan dengan aktivitas mobilitas masyarakat, seperti perjalanan kerja, pendidikan, dan mobilitas akhir pekan. Temuan ini menjadi dasar penggunaan periode musiman sebesar 7 pada model SARIMA.



Gambar 4. Rata-rata Volume Penumpang Berdasarkan Hari dalam Minggu

Selanjutnya, visualisasi time series digunakan untuk melihat perubahan volume penumpang sepanjang periode pengamatan. Berdasarkan grafik time series, volume penumpang KRL menunjukkan fluktuasi harian yang cukup dinamis. Beberapa lonjakan penumpang terlihat pada periode tertentu, terutama pada hari libur nasional dan cuti bersama. Hal ini menunjukkan bahwa volume penumpang tidak hanya dipengaruhi oleh pola mingguan, tetapi juga oleh faktor kalender dan aktivitas mobilitas masyarakat pada periode tertentu.



Gambar 5. Visualisasi Time Series Volume Penumpang KRL Yogyakarta–Solo

Secara umum, karakteristik data pada penelitian ini menunjukkan adanya kombinasi pola musiman mingguan dan fluktuasi temporal. Oleh karena itu, penelitian ini membandingkan model SARIMA, LSTM, dan hibrida SARIMA-LSTM. SARIMA digunakan untuk menangkap pola linier dan musiman, LSTM digunakan untuk mempelajari pola historis dan kemungkinan pola nonlinier secara langsung, sedangkan hibrida SARIMA-LSTM digunakan untuk menguji efektivitas pemodelan residual SARIMA menggunakan LSTM.

3.2 Hasil Preprocessing Data

Tahap preprocessing dilakukan untuk memastikan dataset berada dalam kondisi bersih, konsisten, dan siap digunakan pada proses pemodelan *forecasting*. Dataset volume penumpang KRL Yogyakarta–Solo memiliki karakteristik data deret waktu harian, sehingga proses preprocessing dilakukan dengan tetap mempertahankan urutan temporal data.

Pada tahap ini dilakukan beberapa proses utama, yaitu pemeriksaan data duplikat, pengecekan missing value, transformasi format tanggal, konversi format numerik pada atribut jumlah penumpang, *feature engineering* berbasis kalender, serta pembagian data training dan testing secara kronologis. Atribut tanggal dikonversi ke format datetime agar dapat digunakan dalam analisis *time series*, sedangkan atribut jumlah penumpang dikonversi ke format numerik agar dapat diproses pada model *forecasting*.

Tahap *feature engineering* dilakukan dengan menambahkan beberapa variabel temporal, yaitu hari dalam minggu, status akhir pekan, status hari libur nasional, dan status cuti bersama. Penambahan fitur tersebut bertujuan untuk membantu analisis karakteristik data, khususnya dalam mengidentifikasi pola perubahan volume penumpang yang dipengaruhi oleh aktivitas mobilitas masyarakat pada periode tertentu.

Untuk kebutuhan model LSTM, data residual hasil model SARIMA dinormalisasi menggunakan metode MinMaxScaler agar berada pada rentang nilai yang seragam. Proses normalisasi dilakukan karena LSTM sensitif terhadap skala data. Selanjutnya, data residual dibentuk menjadi sequence menggunakan pendekatan *sliding window* sehingga model dapat mempelajari pola residual berdasarkan periode sebelumnya.

Dataset yang telah melalui proses preprocessing kemudian dibagi menjadi data training dan data testing dengan komposisi 80:20 secara kronologis. Pembagian kronologis digunakan karena data memiliki karakteristik *time series*, sehingga urutan waktu harus dipertahankan dan data testing tidak boleh memengaruhi proses pelatihan model.


Tabel 2. Ringkasan Dataset dan Pembagian Data

Keterangan	Jumlah Data
Total data harian	365
Data training 80%	292
Data testing 20%	73
Periode data	Januari–Desember 2025
Target prediksi	Volume penumpang harian


Berdasarkan Tabel 2, dataset yang digunakan terdiri dari 365 data harian dengan periode pengamatan Januari hingga Desember 2025. Sebanyak 292 data digunakan sebagai data training, sedangkan 73 data digunakan sebagai data testing. Pembagian ini dilakukan secara kronologis untuk menjaga karakteristik deret waktu dan menghindari terjadinya data leakage pada proses pemodelan.

3.3. Hasil Model SARIMA

Pada tahap pemodelan awal digunakan *Seasonal Autoregressive Integrated Moving Average* (SARIMA) sebagai baseline model. SARIMA dipilih karena mampu memodelkan pola linier dan musiman pada data deret waktu. Penentuan parameter dilakukan melalui analisis *Auto Correlation Function* (ACF), *Partial Auto Correlation Function* (PACF), serta evaluasi nilai *Akaike Information Criterion* (AIC). Berdasarkan hasil analisis, data penumpang harian menunjukkan pola musiman mingguan, sehingga periode musiman ditetapkan sebesar 7. Model terbaik yang digunakan adalah SARIMA(2,1,2)(1,1,1)(₇).



Gambar 6. ACF Data Penumpang KRL



Gambar 7. PACF Data Penumpang KRL

Grafik ACF digunakan untuk membantu mengidentifikasi komponen *moving average* (MA) dan pola autokorelasi musiman, sedangkan grafik PACF digunakan untuk membantu mengidentifikasi komponen *autoregressive* (AR). Berdasarkan pola autokorelasi yang terbentuk, data penumpang harian menunjukkan adanya pola musiman mingguan sehingga periode musiman ditetapkan sebesar 7. Selain menggunakan ACF dan PACF, pemilihan model akhir juga mempertimbangkan nilai *Akaike Information Criterion* (AIC). Beberapa kombinasi parameter SARIMA diuji untuk memperoleh model dengan nilai AIC terbaik. Berdasarkan hasil evaluasi tersebut, model yang digunakan dalam penelitian ini adalah SARIMA(2,1,2)(1,1,1)₇ karena menghasilkan nilai AIC paling rendah dibandingkan beberapa kombinasi parameter lain yang diuji.

Hasil evaluasi model SARIMA ditunjukkan pada Tabel 3.


Tabel 3. Hasil Evaluasi Model SARIMA

Metrik	Nilai
MAE	2644,81
RMSE	3299,78
MAPE	10,56 %

Berdasarkan hasil evaluasi, model SARIMA memperoleh nilai MAE sebesar 2644,81, RMSE sebesar 3299,78, dan MAPE sebesar 10,56%. Nilai MAPE tersebut menunjukkan bahwa model SARIMA memiliki performa *forecasting* yang cukup baik dalam memprediksi volume penumpang KRL Yogyakarta–Solo.

Hasil evaluasi menunjukkan bahwa model SARIMA memperoleh MAE sebesar 2644,81, RMSE sebesar 3299,78, dan MAPE sebesar 10,56%. Nilai tersebut menunjukkan bahwa SARIMA mampu menghasilkan *forecasting* dengan tingkat kesalahan yang masih dapat diterima, terutama karena MAPE berada pada kisaran sekitar 10%. Secara praktis, nilai MAE sebesar 2644,81 menunjukkan bahwa rata-rata selisih absolut antara hasil *forecasting* dan data aktual adalah sekitar 2.645 penumpang per hari. Berdasarkan grafik *forecasting*, SARIMA mampu mengikuti pola umum pergerakan volume penumpang, terutama pada pola musiman mingguan yang relatif stabil. Namun, model ini masih menghasilkan deviasi pada beberapa titik dengan perubahan jumlah penumpang yang tajam. Kondisi tersebut menunjukkan bahwa SARIMA cukup efektif dalam menangkap pola *linier* dan musiman, tetapi memiliki keterbatasan ketika data dipengaruhi oleh fluktuasi nonlinier atau faktor eksternal seperti hari libur nasional, cuti bersama, aktivitas wisata, dan perubahan perilaku mobilitas masyarakat.

Temuan ini sesuai dengan karakteristik SARIMA sebagai model statistik deret waktu yang kuat dalam merepresentasikan pola *autoregressive*, *moving average*, *differencing*, dan musiman. Namun, SARIMA cenderung kurang fleksibel dalam menangkap perubahan yang tidak berpola reguler. Oleh karena itu, meskipun SARIMA dapat digunakan sebagai *baseline* yang baik, model ini belum sepenuhnya mampu merepresentasikan dinamika volume penumpang KRL yang dipengaruhi oleh pola kalender dan mobilitas masyarakat.



Gambar 8. Grafik *Forecasting* SARIMA

Gambar 8 menyajikan perbandingan antara data aktual dan hasil *forecasting* model SARIMA. Berdasarkan visualisasi tersebut, model SARIMA secara umum mampu mengikuti arah pergerakan volume penumpang. Namun, pada beberapa titik dengan perubahan jumlah penumpang yang cukup tajam, masih terlihat adanya deviasi antara hasil *forecasting* dan data aktual.


3.4 Hasil Model hybrid SARIMA-LSTM

Dalam upaya meningkatkan akurasi *forecasting* volume penumpang, model SARIMA dikombinasikan dengan *Long Short-Term Memory* (LSTM) melalui pendekatan pemodelan *residual error*. Model SARIMA terlebih dahulu digunakan untuk menghasilkan *forecasting* awal pada data penumpang. Selanjutnya, *residual error* yang diperoleh dari selisih antara data aktual dan hasil *forecasting* SARIMA digunakan sebagai input pada model LSTM.

Residual error tersebut dinormalisasi menggunakan *MinMaxScaler* agar berada pada rentang nilai yang seragam. Setelah itu, data residual dibentuk menjadi sequence menggunakan pendekatan *sliding window* dengan window size sebesar 7. Model LSTM kemudian dilatih untuk mempelajari pola residual yang belum mampu ditangkap oleh model SARIMA. Output dari model LSTM berupa prediksi residual digunakan sebagai nilai koreksi terhadap hasil *forecasting* SARIMA, sehingga diperoleh hasil akhir *forecasting* dari model hybrid SARIMA-LSTM.

Tabel 4. Hasil Evaluasi Model SARIMA-LSTM

Metrik	Nilai
MAE	2634,78
RMSE	3294,24
MAPE	10,52%



Gambar 9. Grafik *Forecasting SARIMA-LSTM*

Hasil evaluasi menunjukkan bahwa model hibrida SARIMA-LSTM memperoleh MAE sebesar 2634,78, RMSE sebesar 3294,24, dan MAPE sebesar 10,52%. Jika dibandingkan dengan SARIMA tunggal, model hibrida hanya menurunkan MAE sebesar 10,03, RMSE sebesar 5,54, dan MAPE sebesar 0,04%. Penurunan tersebut menunjukkan adanya perbaikan, tetapi peningkatannya sangat kecil secara praktis. Kecilnya peningkatan performa menunjukkan bahwa residual SARIMA pada dataset ini belum mengandung pola nonlinier yang cukup kuat untuk dipelajari secara optimal oleh LSTM. Jika sebagian besar pola linier dan musiman sudah ditangkap oleh SARIMA, maka residual yang tersisa cenderung bersifat acak atau memiliki struktur pola yang lemah. Dalam kondisi tersebut, LSTM tidak memperoleh informasi temporal yang cukup signifikan untuk menghasilkan koreksi residual yang besar.

Secara teoritis, model hibrida SARIMA-LSTM diharapkan mampu menggabungkan kelebihan SARIMA dalam menangkap pola linier-musiman dan kelebihan LSTM dalam menangkap pola nonlinier. Namun, hasil penelitian ini menunjukkan bahwa efektivitas pendekatan hibrida sangat bergantung pada karakteristik residual, jumlah data historis, dan kompleksitas pola yang tersisa setelah pemodelan SARIMA. Dengan demikian, model hibrida tidak selalu menghasilkan performa terbaik apabila residual yang dipelajari tidak memiliki pola nonlinier yang jelas.

3.5 Hasil Model LSTM


Selain model SARIMA dan hibrida SARIMA-LSTM, penelitian ini juga menguji *model Long Short-Term Memory (LSTM)* sebagai model *deep learning*. Model LSTM digunakan untuk mempelajari pola historis volume penumpang secara langsung berdasarkan data deret waktu harian. Berbeda dengan model hibrida SARIMA-LSTM yang menggunakan *residual error* SARIMA sebagai input, model LSTM menggunakan data historis volume penumpang sebagai input utama untuk menghasilkan *forecasting*.

Sebelum proses pelatihan dilakukan, data volume penumpang dinormalisasi menggunakan metode *MinMaxScaler* agar berada pada rentang nilai yang seragam. Normalisasi dilakukan karena model LSTM sensitif terhadap perbedaan skala data. Setelah itu, data dibentuk menjadi *sequence* menggunakan pendekatan *sliding window* dengan *window size* sebesar 7. Penggunaan *window size* 7 disesuaikan dengan pola mingguan pada data penumpang harian KRL Yogyakarta–Solo.

Model LSTM dilatih menggunakan data *training* dan diuji menggunakan data *testing* yang telah dibagi secara kronologis. Hasil *forecasting* kemudian dikembalikan ke skala asli agar dapat dibandingkan dengan data aktual. Evaluasi performa model LSTM dilakukan menggunakan metrik MAE, RMSE, dan MAPE.

Tabel 5. Hasil Evaluasi Model LSTM

Metrik	Nilai
MAE	1977,50
RMSE	2528,75
MAPE	7,28%



Gambar 10. Grafik *Forecasting* LSTM

Berdasarkan hasil evaluasi pada Tabel 5, Hasil evaluasi menunjukkan bahwa LSTM memperoleh MAE sebesar 1977,50, RMSE sebesar 2528,75, dan MAPE sebesar 7,28%. Nilai tersebut merupakan *error* paling rendah dibandingkan SARIMA dan *hibrida* SARIMA-LSTM. Secara praktis, MAE sebesar 1977,50 menunjukkan bahwa rata-rata selisih antara hasil forecasting dan data aktual adalah sekitar 1.978 penumpang per hari. Performa LSTM yang lebih baik menunjukkan bahwa model ini mampu mempelajari pola historis dan dinamika temporal volume penumpang secara lebih fleksibel. Berbeda dengan SARIMA yang mengasumsikan struktur linier dan musiman, LSTM dapat mempelajari hubungan temporal yang lebih kompleks melalui mekanisme *memory cell* dan *gate*. Hal ini membuat LSTM lebih mampu mengikuti fluktuasi data yang tidak sepenuhnya reguler.

Hasil ini sejalan dengan karakteristik *deep learning* pada data deret waktu, khususnya LSTM yang dirancang untuk mempelajari dependensi jangka pendek maupun jangka panjang. Pada dataset KRL Yogyakarta–Solo, pola volume penumpang tidak hanya dipengaruhi oleh musiman mingguan, tetapi juga oleh perubahan aktivitas masyarakat dan faktor kalender. Oleh karena itu, kemampuan LSTM dalam mempelajari pola temporal yang lebih kompleks menjadi alasan utama model ini menghasilkan performa *forecasting* terbaik.

3.6 Perbandingan Performa Model


Perbandingan performa model dilakukan untuk mengevaluasi kemampuan masing-masing pendekatan dalam melakukan *forecasting* volume penumpang KRL Yogyakarta–Solo. Model yang dibandingkan dalam penelitian ini meliputi SARIMA, LSTM, dan *hibrida* SARIMA-LSTM. Data aktual digunakan sebagai acuan pembandingan atau ground truth untuk mengukur tingkat kesalahan hasil *forecasting* dari masing-masing model. Evaluasi dilakukan menggunakan tiga metrik utama, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Model dengan nilai error yang lebih kecil dinilai memiliki performa forecasting yang lebih baik. Hasil perbandingan performa model ditunjukkan pada Tabel 6.

Tabel 6. Perbandingan performa model

Model	MAE	RMSE	MAPE	Δ MAE	Δ RMSE	Δ MAPE
SARIMA	2644,81	3299,78	10,56%	-	-	-
LSTM	1977,50	2528,75	7,28%	667,31	771,03	3,28%
SARIMA-LSTM	2634,78	3294,24	10,52%	10,03	5,54	0,04%

Berdasarkan hasil evaluasi pada Tabel 6, LSTM menjadi model dengan performa terbaik pada seluruh metrik. LSTM memperoleh MAE sebesar 1977,50, RMSE sebesar 2528,75, dan MAPE sebesar 7,28%. Dibandingkan SARIMA, LSTM menurunkan MAE sebesar 667,31, RMSE sebesar 771,03, dan MAPE sebesar 3,28%. Penurunan ini menunjukkan bahwa LSTM memberikan peningkatan akurasi yang lebih signifikan dibandingkan pendekatan statistik musiman. SARIMA memperoleh MAPE sebesar 10,56%, sedangkan *hibrida* SARIMA-LSTM memperoleh MAPE sebesar 10,52%. Selisih MAPE sebesar 0,04% menunjukkan bahwa integrasi LSTM pada residual SARIMA hanya memberikan perbaikan yang sangat kecil. Dengan demikian, model *hibrida* memang lebih baik dibandingkan SARIMA, tetapi peningkatannya belum cukup kuat untuk disebut signifikan secara praktis.

Perbandingan visual antara data aktual dan hasil forecasting dari masing-masing model ditunjukkan pada Gambar 11.



Gambar 11. Perbandingan Data Aktual, SARIMA, LSTM, dan Hibrida SARIMA-LSTM

Gambar 11 menunjukkan empat seri data, yaitu data aktual, hasil *forecasting* SARIMA, hasil *forecasting* LSTM, dan hasil *forecasting* hibrida SARIMA-LSTM. Data aktual digunakan sebagai acuan untuk melihat sejauh mana setiap model mampu mengikuti pola perubahan volume penumpang. Secara umum, model SARIMA mampu mengikuti pola musiman utama, tetapi masih memiliki deviasi pada beberapa periode fluktuatif. Secara visual, grafik perbandingan menunjukkan bahwa SARIMA dan hibrida SARIMA-LSTM mampu mengikuti pola umum data aktual, tetapi masih memiliki deviasi pada beberapa periode fluktuatif. LSTM terlihat lebih mendekati data aktual, terutama pada perubahan volume penumpang yang tidak sepenuhnya mengikuti pola musiman reguler. Temuan visual ini konsisten dengan hasil evaluasi numerik pada MAE, RMSE, dan MAPE.

Perbedaan performa ini menunjukkan bahwa data penumpang KRL Yogyakarta–Solo memiliki pola yang tidak hanya bersifat linier dan musiman, tetapi juga mengandung dinamika temporal yang lebih kompleks. SARIMA tetap relevan sebagai baseline karena mampu menangkap pola musiman mingguan. Namun, LSTM lebih unggul karena mampu mempelajari pola historis dan kemungkinan hubungan nonlinier secara langsung dari data..

3.7 Analisis dan Pembahasan

Hasil penelitian menunjukkan bahwa setiap model memiliki karakteristik performa yang berbeda. SARIMA mampu menangkap pola musiman mingguan, tetapi masih terbatas dalam mengikuti fluktuasi tajam. LSTM menghasilkan performa terbaik karena mampu mempelajari pola temporal dan kemungkinan pola nonlinier secara lebih fleksibel. Sementara itu, hibrida SARIMA-LSTM hanya memberikan sedikit perbaikan dibandingkan SARIMA karena residual SARIMA belum memiliki pola nonlinier yang cukup kuat untuk dipelajari oleh LSTM.

Temuan ini mendukung penelitian Fajarianto et al. [15] dan Priyanto et al. [6] yang menunjukkan bahwa metode statistik masih dapat digunakan untuk forecasting jumlah penumpang transportasi publik. Namun, hasil penelitian ini juga memperluas temuan tersebut dengan menunjukkan bahwa pendekatan deep learning, khususnya LSTM, dapat memberikan performa lebih baik ketika data memiliki pola temporal yang lebih kompleks. Hasil ini sejalan dengan penelitian Lu dan Wang [7], Sun et al. [8], serta kajian Di Torrepadula et al. [3] yang menyatakan bahwa *machine learning* dan deep learning memiliki kemampuan lebih baik dalam menangani kompleksitas data transportasi publik, terutama pada pola nonlinier dan dinamika temporal.

Keunggulan LSTM pada penelitian ini dapat dijelaskan melalui dua aspek. Pertama, data volume penumpang harian KRL Yogyakarta–Solo tidak hanya memiliki pola musiman mingguan, tetapi juga dipengaruhi oleh variasi kalender, hari libur, cuti bersama, dan aktivitas mobilitas masyarakat. Kedua, LSTM memiliki kemampuan mempelajari hubungan temporal berdasarkan urutan data historis melalui mekanisme *memory cell* dan *gate*, sehingga lebih fleksibel dalam menangkap pola perubahan yang tidak sepenuhnya linier. Hal ini menyebabkan LSTM menghasilkan nilai error lebih rendah dibandingkan SARIMA dan hibrida SARIMA-LSTM.

Model hibrida SARIMA-LSTM memperoleh MAE sebesar 2634,78, RMSE sebesar 3294,24, dan MAPE sebesar 10,52%. Jika dibandingkan dengan SARIMA, model hibrida hanya menurunkan MAPE sebesar 0,04%. Hasil ini menunjukkan bahwa integrasi LSTM pada residual SARIMA memang memberikan perbaikan, tetapi kontribusinya masih relatif kecil secara praktis. Secara konseptual, model hibrida diharapkan mampu menggabungkan kekuatan SARIMA dalam menangkap pola linier dan musiman dengan kemampuan LSTM dalam mempelajari pola nonlinier. Namun, hasil penelitian ini menunjukkan bahwa pendekatan hibrida tidak selalu menghasilkan performa terbaik. Kecilnya peningkatan performa pada model hibrida dapat disebabkan oleh karakteristik *residual* SARIMA. Apabila SARIMA sudah mampu menangkap sebagian besar pola tren dan musiman, maka residual yang tersisa cenderung lebih acak atau memiliki pola yang lemah. Akibatnya, LSTM tidak memperoleh informasi tambahan yang cukup signifikan untuk menghasilkan koreksi terhadap hasil forecasting SARIMA. Dengan demikian, efektivitas model hibrida sangat bergantung pada karakteristik residual, jumlah data historis, dan ketersediaan variabel eksternal.

Berdasarkan hasil tersebut, pemilihan model forecasting perlu disesuaikan dengan karakteristik dataset. Pada data volume penumpang harian KRL Yogyakarta–Solo, LSTM menjadi model terbaik berdasarkan nilai MAE, RMSE, dan MAPE. SARIMA tetap relevan digunakan sebagai baseline untuk menangkap pola musiman mingguan, sedangkan hibrida SARIMA-LSTM masih dapat dikembangkan lebih lanjut dengan data historis yang lebih panjang, optimasi hyperparameter, dan penambahan variabel eksternal seperti cuaca, event wisata, kalender akademik, serta jadwal operasional KRL.

3.8 Keterbatasan Penelitian dan *Future Research*

Penelitian ini memiliki beberapa keterbatasan. Pertama, dataset yang digunakan hanya mencakup data harian selama satu tahun, yaitu periode Januari hingga Desember 2025. Jumlah data tersebut relatif terbatas, khususnya untuk mendukung proses pembelajaran model *deep learning* yang umumnya membutuhkan data historis lebih panjang agar mampu mengenali pola temporal dan nonlinier secara lebih optimal.

Kedua, variabel eksternal yang digunakan dalam penelitian ini masih terbatas pada fitur berbasis kalender, seperti hari dalam minggu, status akhir pekan, hari libur nasional, dan cuti bersama. Padahal, volume penumpang KRL juga dapat dipengaruhi oleh faktor lain, seperti cuaca, kalender akademik, event lokal, aktivitas pariwisata, jadwal operasional perjalanan, dan kondisi sosial ekonomi masyarakat. Keterbatasan variabel eksternal dapat menyebabkan model belum sepenuhnya mampu menangkap faktor-faktor yang memengaruhi lonjakan atau penurunan jumlah penumpang.

Ketiga, model hibrida SARIMA-LSTM yang digunakan dalam penelitian ini masih menggunakan pendekatan *residual* sederhana, yaitu residual SARIMA dipelajari menggunakan LSTM untuk menghasilkan koreksi terhadap hasil *forecasting* SARIMA. Pada dataset yang digunakan, pendekatan ini belum mampu mengungguli model LSTM. Hal ini menunjukkan bahwa strategi hibridisasi model masih perlu dikembangkan lebih lanjut, misalnya melalui optimasi arsitektur LSTM, *tuning hyperparameter*, penggunaan *window size* yang berbeda, atau integrasi variabel eksternal secara langsung ke dalam model.

Untuk penelitian selanjutnya, disarankan menggunakan data historis dengan periode yang lebih panjang, misalnya data dua hingga lima tahun, agar pola musiman tahunan, pola libur panjang, dan perubahan tren mobilitas dapat dianalisis secara lebih komprehensif. Selain itu, penelitian berikutnya dapat menambahkan variabel eksternal seperti data cuaca, kalender akademik, event wisata, jumlah perjalanan KRL, dan data kepadatan stasiun. Penelitian selanjutnya juga dapat membandingkan model SARIMA-LSTM dengan pendekatan lain seperti GRU, Bi-LSTM, *Attention-Based LSTM*, Prophet, XGBoost, *Random Forest*, atau *Transformer* untuk memperoleh gambaran performa *forecasting* yang lebih menyeluruh.

4. KESIMPULAN

Berdasarkan hasil penelitian, model SARIMA, LSTM, dan hibrida SARIMA-LSTM dapat digunakan untuk forecasting volume penumpang harian KRL Yogyakarta–Solo dengan karakteristik performa yang berbeda. SARIMA mampu menangkap pola musiman mingguan, tetapi masih terbatas dalam mengikuti fluktuasi tajam. LSTM menghasilkan performa terbaik dengan MAE sebesar 1977,50, RMSE sebesar 2528,75, dan MAPE sebesar 7,28%, lebih rendah dibandingkan SARIMA yang memperoleh MAE sebesar 2644,81, RMSE sebesar 3299,78, dan MAPE sebesar 10,56%, serta hibrida SARIMA-LSTM yang memperoleh MAE sebesar 2634,78, RMSE sebesar 3294,24, dan MAPE sebesar 10,52%. Hasil tersebut menunjukkan bahwa LSTM lebih efektif dalam mempelajari pola historis dan kemungkinan pola nonlinier pada data penumpang harian. Sementara itu, hibrida SARIMA-LSTM hanya memberikan sedikit perbaikan dibandingkan SARIMA karena residual SARIMA belum memiliki pola nonlinier yang cukup kuat untuk dipelajari oleh LSTM. Dengan demikian, pemilihan model forecasting perlu mempertimbangkan karakteristik dataset, pola musiman, pola residual, dan kecukupan data historis. Penelitian selanjutnya disarankan menggunakan data historis yang lebih panjang serta menambahkan variabel eksternal untuk meningkatkan akurasi *forecasting*.

UCAPAN TERIMA KASIH

Penulis menyampaikan apresiasi yang sebesar-besarnya kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia atas pendanaan hibah Penelitian Dosen Pemula dengan nomo kontrak 045/UDB.LPPM/A.34-HK/II/2026, LLDIKTI Wilayah VI Jawa Tengah, serta Universitas Duta Bangsa Surakarta atas dukungan yang telah diberikan dalam bentuk fasilitasi, bimbingan, pendanaan dan pendampingan selama proses penelitian dan penyusunan naskah ini berlangsung.

REFERENCES

- [1] Kementerian Riset dan Teknologi/Badan Riset dan Inovasi Nasional, "Prioritas Riset Nasional (PRIN) 2020-2024: Fokus Transportasi dan Ketahanan Pangan," Jakarta, 2020.
- [2] KIP PT KCI, "Laporan Data Berkala Informasi Publik," 2025. [Online]. Available: <https://kip.kci.id/info-berkala>. [Accessed: Mar. 5, 2026].

- [3] F. R. Di Torrepadula, E. V. Napolitano, S. Di Martino, and N. Mazzocca, "Machine learning for public transportation demand prediction: a systematic literature review," *Engineering Applications of Artificial Intelligence*, vol. 137, p. 109166, 2024. DOI: 10.1016/j.engappai.2024.109166.
- [4] F. Ely Nastiti, S. Musa, E. Yafi, and M. Ardiyanto, "Epidemic Prognosis: Comparative Performance Of Machine Learning And Deep Learning Models For Predicting Virus Transmission Dynamics," in *Proceeding Int. Conf. Sci. Health Technol.*, Sep. 2023, pp. 260–270. DOI: 10.47701/icohetech.v4i1.3401
- [5] R. D. Irawan and A. Fatkhurohman, "Application of Deep Learning Algorithm to Detect Fraud in Online Transaction Networks," *J. Teknol. dan Open Source*, vol. 7, no. 2, pp. 167–177, Dec. 2024. DOI: 10.36378/jtos.v7i2.3890.
- [6] S. Priyanto, E. Churniawan, D. S. Oktaria, and E. S. Darmawan, "Forecasting the Number of Jogja-Solo KRL Passengers with the Gray Method (1,1), Moving Average and Exponential Smoothing," *J. World Sci.*, vol. 2, no. 1, pp. 138–149, Jan. 2023, DOI: 10.58344/jws.v2i1.130.
- [7] Y. Lu and J. Wang, "Short-Term Passenger Flow Forecasting for Rail Transit Integrating Multi-Scale Decomposition and Deep Attention Mechanism," *Sustainability*, vol. 17, no. 19, p. 8880, 2025. DOI: 10.3390/su17198880.
- [8] J. Sun, X. Ye, X. Yan, T. Wang, and J. Chen, "Multi-Step Peak Passenger Flow Prediction of Urban Rail Transit Based on Multi-Station Spatio-Temporal Feature Fusion Model," *Systems*, vol. 13, no. 2, p. 96, 2025. DOI: 10.3390/systems13020096.
- [9] M. D. Purnama, "Enhancing Tourism Demand Forecasting Accuracy Through Clustering Time Series: A Comparison MAPE Analysis of Indonesian Provincial Domestic Tourist Flows," *Eng. Math. Comput. Sci. J. EMACS*, vol. 7, no. 3, pp. 353–362, Sep. 2025. DOI: 10.21512/emacsjournal.v7i3.14112
- [10] D. D. Chuwang and W. Chen, "Forecasting Daily and Weekly Passenger Demand for Urban Rail Transit Stations Based on a Time Series Model Approach," *Forecasting*, vol. 4, no. 4, pp. 904–924, Nov. 2022. DOI: 10.1016/j.asoc.2023.110740
- [11] Y. Xi and X. Deng, "Machine Learning-Based Short-Term Traffic Flow Prediction Model for Metro Systems," in *2025 8th Int. Conf. Adv. Electron. Mater. Comput. Softw. Eng. (AEMCSE)*, Nanjing, China, 2025, pp. 168–171. DOI: AEMCSE65292.2025.11042735
- [12] E. D. Rahmawati, R. Setiyani, A. A. Janah, R. Subagyo, and Nurkhasanah, "Kualitas Layanan dan Kepuasan Wisatawan sebagai Penentu Niat Kunjungan Ulang: Studi pada Wisata Geopark Kebumen," *Simetris: Jurnal Ilmu Keuangan, Perbankan dan Ekonomi Terapan*, vol. 4, no. 2, pp. 185–198, 2024. [Online]. Available: <https://www.ejurnal.teraskampus.id/index.php/simetris/article/view/358>
- [13] G. Shi and L. Luo, "Prediction and Impact Analysis of Passenger Flow in Urban Rail Transit in the Postpandemic Era," *J. Adv. Transp.*, vol. 2023, pp. 1–12, Aug. 2023. DOI: 10.1155/2023/3448864
- [14] M. A. Shafique, "Improving ridership by predicting train occupancy levels," *J. Public Transp.*, vol. 26, p. 100092, 2024. DOI: 10.1016/j.jpubtr.2024.100092
- [15] G. W. Fajarianto, J. F. Ramadhani, S. C. Kusuma, and M. Zarkasi, "Predicting the Number of Passengers on Electric Rail Trains (KRL) in Jabodetabek Using the ARIMA Method," *Brill. Res. Artif. Intell.*, vol. 5, no. 1, pp. 425–433, Jul. 2025. DOI: 10.47709/brilliance.v5i1.6347
- [16] N. Passalis, A. Tefas, J. Kannianen, M. Gabbouj, and A. Iosifidis, "Deep Adaptive Input Normalization for Time Series Forecasting," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 31, no. 9, pp. 3760–3765, Sep. 2020, DOI: 10.1109/TNNLS.2019.2944933.
- [17] U. M. Sirisha, M. C. Belavagi, and G. Attigeri, "Profit Prediction Using ARIMA, SARIMA and LSTM Models in Time Series Forecasting: A Comparison," *IEEE Access*, vol. 10, pp. 124715–124727, 2022, DOI: 10.1109/ACCESS.2022.3224938.
- [18] R. Thiagarajan and S. P. Kumar, "Performance of public transport appraisal using machine learning," *Sci. Temper*, vol. 15, no. spl-1, pp. 373–378, Feb. 2025. DOI: 10.17762/ijritcc.v11i11.9900
- [19] J. E. Barrera Hernandez, L. E. Tarazona Torres, A. Tabares, and D. Álvarez-Martínez, "Optimization of Bus Dispatching in Public Transportation Through a Heuristic Approach Based on Passenger Demand Forecasting," *Smart Cities*, vol. 8, no. 3, p. 87, May 2025. DOI: 10.3390/smartcities8030087.
- [20] M. Milenković and N. Bojović, "Forecasting passenger flow volumes on Serbian railways: A comparative analysis of univariate and multivariate approaches," *Research in Transportation Business & Management*, vol. 63, Art. no. 101491, 2025, DOI: 10.1016/j.rtbm.2025.101491.
- [21] D. H. Hopfe, K. Lee, and C. Yu, "Short-term forecasting airport passenger flow during periods of volatility: Comparative investigation of time series vs. neural network models," *Journal of Air Transport Management*, vol. 110, Art. no. 102525, 2024, DOI: 10.1016/j.jairtraman.2023.102525.
- [22] T. Zuo, S. Tang, L. Zhang, H. Kang, H. Song, and P. Li, "An Enhanced TimesNet-SARIMA Model for Predicting Outbound Subway Passenger Flow with Decomposition Techniques," *Applied Sciences*, vol. 15, no. 6, Art. no. 2874, 2025, DOI: 10.3390/app15062874.