

Penerapan Metode *Seasonal Autoregressive Integrated Moving Average* dalam Meramalkan Jumlah Penumpang Kereta Api

Nurul Latifah Hanum¹, Riry Sriningsih²

^{1,2} Program Studi Matematika, Fakultas Matematika Ilmu Pengetahuan dan Alam, Universitas Negeri Padang (UNP)

Article Info

Article history:

Received May 12, 2025

Revised May 25, 2025

Accepted June 02, 2025

Keywords:

Train

Seasonal Autoregressive
Integrated Moving Average
Forecasting

Kata Kunci:

Kereta Api

Seasonal Autoregressive
Integrated Moving Average
Peramalan

ABSTRACT

As one of the preferred land transportation for the people of West Sumatra, trains are often the main choice for people to travel. Data from PT. KAI shows a surge in the number of passengers in certain periods, such as semester breaks or national holidays. During these periods, some passengers are unable to get seats, which may reduce public interest in using train services. This study aims to forecast the number of railway passengers from October 2024 to September 2025 using the best-fitting model. The method applied is the Seasonal Autoregressive Integrated Moving Average (SARIMA). The results showed that the best model for forecasting is $ARIMA(1,1,1)(0,1,1)^{12}$. Based on this model, the number of train passengers is predicted to range from 149,799 to 192,338, with the highest number predicted to occur in December 2024.

ABSTRAK

Sebagai salah satu transportasi darat yang diminati oleh masyarakat Sumatera Barat, kereta api sering menjadi pilihan utama Masyarakat untuk bepergian. Data dari PT. KAI menunjukkan adanya lonjakan jumlah penumpang pada periode-periode tertentu, seperti pada periode libur semester atau pada periode yang mencakup hari libur nasional di dalamnya. Pada periode tersebut biasanya sebagian penumpang kereta api tidak mendapatkan tempat duduk. Jika kondisi ini dibiarkan berlanjut, maka minat penumpang untuk menggunakan kereta api akan berkurang. Penelitian ini mempunyai tujuan guna mendapatkan hasil ramalan jumlah penumpang kereta api pada Oktober 2024 sampai September 2025 berdasarkan model terbaik yang terpilih. Metode yang dipakai dalam penelitian ini yakni *Seasonal Autoregressive Integrated Moving Average*. Hasil penelitian membuktikan jika model paling sesuai untuk peramalan ialah $ARIMA(1,1,1)(0,1,1)^{12}$. Berdasarkan model ini, jumlah penumpang kereta api diperkirakan berkisar antara 149.799 hingga 192.338, dengan jumlah tertinggi diprediksi terjadi pada Desember 2024.

This is an open access article under the [CC BY-SA](#) license.



Nurul Latifah Hanum

Program Studi Matematika, Departemen Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Negeri Padang, Jl. Prof. Dr. Hamka, Air Tawar barat, Padang Utara, Padang, Indonesia. Kode Pos: 25131
Email: latifahhanum389@gmail.com

1. PENDAHULUAN

Transportasi diartikan selaku pemindahan orang atau barang dari sebuah tempat menuju tempat lainnya, yang mana di dalamnya ditemukan elemen pergerakan (*movement*). Transportasi memiliki peran krusial guna membentuk struktur ekonomi serta sosial masyarakat, serta menjadi faktor utama dalam kelancaran pergerakan orang, barang, dan jasa. Di Indonesia sendiri, transportasi memainkan



peranan yang sangat penting karena tidak ada elemen kehidupan masyarakat Indonesia yang tidak disentuh oleh transportasi [1].

Di Sumatera Barat, jenis transportasi yang umum digunakan untuk bepergian adalah bus, travel, dan moda transportasi yang dapat mengangkut banyak penumpang, seperti kereta api. Di antara pilihan tersebut, kereta api merupakan pilihan angkutan darat yang paling sering digunakan masyarakat [2]. Dengan jalur yang menghubungkan berbagai daerah di Sumatera Barat, kereta api menawarkan kemudahan akses dan efisiensi waktu, sehingga menjadi pilihan utama bagi banyak orang ketika bepergian ke luar kota atau daerah. Selain harga tiketnya yang relatif terjangkau, kereta api merupakan transportasi anti macet yang dapat menyelesaikan permasalahan kemacetan yang kerap ditemukan di jalan-jalan, terutama di kota-kota besar [1] [3]. Hal ini membuat kereta api menjadi pilihan yang diminati oleh banyak orang, khususnya di Sumatera Barat.

Berdasarkan catatan dari PT. KAI, jumlah penumpang kereta api selalu bertambah setiap tahunnya, khususnya pada bulan-bulan tertentu seperti halnya pada periode libur semester atau pada periode yang mencakup hari libur nasional di dalamnya. Pada periode tersebut biasanya banyak penumpang yang harus berdiri dan menunggu penumpang yang memiliki tempat duduk turun di stasiun terdekat. Jika permasalahan ini dibiarkan maka minat para penumpang untuk menggunakan jasa kereta api akan berkurang karena ketidaknyamanan yang dirasakan. Oleh karena itu perlu dilakukan peramalan sehingga dapat dipersiapkan fasilitas yang lebih baik atau penambahan gerbong kereta api untuk kelancaran transportasi kereta api.

Peramalan (*forecasting*) ialah teknik yang melibatkan penggunaan data historis, yang kemudian diproyeksikan ke masa depan melalui suatu bentuk model matematis dengan tujuan untuk memperkirakan kondisi atau peristiwa di masa mendatang [4] [5]. Teknik ini bertujuan untuk mengurangi tingkat ketidakpastian terhadap masa depan, sehingga pengambilan keputusan dapat dilakukan dengan lebih akurat. Dalam praktiknya, peramalan terbagi menjadi dua pendekatan utama, yaitu peramalan kuantitatif yang berbasis data historis, serta peramalan kualitatif yang lebih mengandalkan penilaian subjektif dan opini para ahli [6].

Salah satu pendekatan kuantitatif yang banyak digunakan dalam peramalan adalah metode deret waktu (*time series*), yaitu teknik analisa data yang digunakan guna melakukan prediksi nilai masa depan berlandaskan atas pola yang teridentifikasi dalam data historis [7]. Metode ini mengasumsikan bahwa sejumlah pola akan senantiasa mengalami perulangan sepanjang waktu. Contoh metode yang dapat dipakai dalam menentukan deret waktu ialah metode *Seasonal Autoregressive Integrated Moving Average*. Metode ini secara umum merupakan pengembangan atas metode *Autoregressive Integrated Moving Average* (ARIMA), bedanya pada *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dikhususkan untuk data yang berpola musiman [8].

Metode *Seasonal Autoregressive Integrated Moving Average* dipilih karena metode ini cocok guna meramalkan data yang membentuk pola musiman [8] [9], yaitu pada saat terjadi lonjakan jumlah penumpang kereta api pada periode-periode tertentu. Selain itu, metode ini memiliki ketepatan yang sangat baik dalam peramalan jangka pendek [10]. Dengan demikian diharapkan peramalan memakai metode *Seasonal Autoregressive Integrated Moving Average* mampu membantu PT. KAI Divisi Regional II Sumatera Barat dalam pengambilan keputusan guna menuntaskan masalah yang ditemukan.

2. METODE

Penelitian ini merupakan penelitian terapan. Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari arsip yang dimiliki PT. KAI Divisi Regional II Sumatera Barat. Analisis data dilakukan dengan pendekatan deret waktu, yang mencakup deteksi *outlier* menggunakan Box Plot [11], pengujian kestasioneran memakai *Augmented Dickey-Fuller* (ADF) test [12], serta penaksiran parameter menggunakan metode *Maximum Likelihood Estimation* (MLE) [4]. Adapun langkah analisa data yang dipakai pada penelitian ini yakni:

- 1) Pengumpulan data dan melakukan analisis deskriptif terhadap data.
- 2) Melakukan deteksi *outlier* pada data menggunakan Box Plot.
- 3) Mengidentifikasi model.

- a) Membuat plot data asli terhadap waktu
- b) Melakukan pemeriksaan kestasioneran data menggunakan *ADF test*.
- c) Melakukan pembedaan (*differencing*) pada data yang tidak stasioner terhadap rata-rata, serta melakukan transformasi pada data yang tidak stasioner terhadap variansi.
- d) Menentukan model sementara melalui plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).
- e) Melakukan *overfitting* terhadap model sementara.
- 4) Penaksiran dan pengujian parameter.
 - a) Melakukan estimasi parameter model dengan metode *Maximum Likelihood Estimation* (MLE).
 - b) Memilih model yang sesuai dengan menggunakan uji signifikansi parameter.
- 5) Pemeriksaan diagnostik.
Melakukan pengecekan asumsi residual melalui penggunaan uji *white noise* serta uji normalitas.
- 6) Menghitung MSE tiap model dan memilih model terbaik berdasarkan MSE terkecil.
- 7) Melakukan peramalan dengan memakai model terbaik.

3. HASIL DAN PEMBAHASAN

3.1. Deskripsi Data

Data yang dipakai ialah data jumlah penumpang kereta api yang diperoleh dari PT. KAI Divisi Regional II Sumatera Barat dalam bentuk data bulanan. Periode data dari Januari 2018 sampai September 2024, dimana periode keseluruhannya adalah 81 periode.

3.2. Analisis Data

1. Statistika Deskriptif

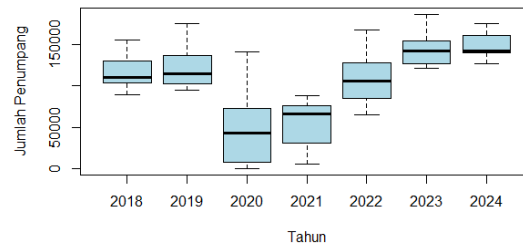
Analisis statistika deskriptif dari data jumlah penumpang kereta api pada bulan Januari 2018 sampai September 2024 diketahui dalam Tabel 1.

Statistik	Nilai
N	81
Mean	104.507
St.Dev	46.196
Maks	186.342
Min	0

Tabel 1 menunjukkan bahwa rata-rata data jumlah penumpang kereta api sebesar 104.507 penumpang per bulan. Standar deviasi menunjukkan nilai 46.196 penumpang per bulan. Sementara itu diketahui jumlah minimum penumpang sebesar 0 penumpang yang terjadi pada bulan Mei 2020 sampai Juli 2020 akibat pemberlakuan pembatasan sosial [13]. Nilai maksimum sebesar 186.342 penumpang menunjukkan jumlah penumpang terbanyak terjadi di bulan Desember 2023.

2. Deteksi *Outlier* Data

Pengecekan *outlier* pada data dilakukan mengingat di tahun 2020 terdapat penurunan signifikan jumlah penumpang kereta api. Kondisi ini berpotensi menghasilkan data yang tidak wajar atau *outlier*, sehingga perlu dilakukan pengecekan menggunakan visualisasi Box Plot yang dapat diketahui dalam Gambar 1.



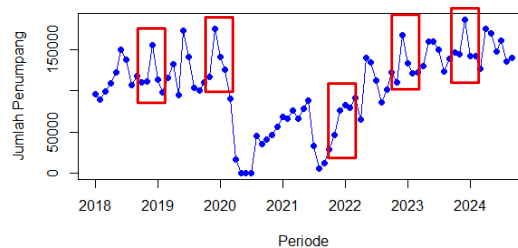
Gambar 1. Box Plot Jumlah Penumpang Kereta Api

Ditinjau dari Gambar 1, diketahui bahwa tidak ada data yang terletak jauh dari *whisker* data. Hal ini menunjukkan bahwa penurunan jumlah penumpang pada tahun 2020 tidak mengakibatkan munculnya *outlier* pada data.

3. Identifikasi Model

a) Membuat Plot Data

Sebelum pemodelan dilakukan, plot data jumlah penumpang kereta api perlu ditampilkan untuk melihat pola yang terjadi dan mengetahui keberadaan musiman pada data.




Gambar 2. Plot Data Jumlah Penumpang Kereta Api

Gambar 2 menunjukkan adanya pola musiman yang konsisten pada setiap tahun, ditandai dengan lonjakan jumlah penumpang pada setiap akhir tahun yang kemungkinan besar berkaitan dengan musim libur sekolah dan libur akhir tahun. Selain itu, tampak adanya penurunan signifikan pada tahun 2020 hingga awal 2021, yang dapat dikaitkan dengan dampak pandemi COVID-19 terhadap mobilitas masyarakat. Setelah periode tersebut, jumlah penumpang kembali mengalami tren peningkatan secara bertahap dan pola musiman kembali muncul secara konsisten hingga tahun 2024.

b) Pemeriksaan Kestasioneran Data

Setelah dilakukan analisis pada plot data, selanjutnya dilakukan evaluasi stasioneritas pada data.




Gambar 3. Plot Data Jumlah Penumpang Kereta Api dengan Garis Rataan

Jika diperhatikan pada Gambar 3, diketahui bahwa data sudah relatif stasioner terhadap variansi, namun data diduga tidak stasioner pada nilai tengah karena ditemukan adanya tren pada data.

Berdasarkan hasil pengujian ADF, diperoleh bahwa nilai p -value ADF sebesar 0,682. Artinya nilai p -value melebihi taraf signifikan $\alpha = 5\%$. Dengan demikian dapat ditarik kesimpulan bahwa data tidak stasioner, sehingga pembedaan (*differencing*) data perlu dilakukan.

c) Proses Pembedaan (*Differencing*) Data

Guna mengatasi ketidakstasioneran data pada nilai tengah, maka dilakukan proses pembedaan terhadap data. Data hasil pembedaan bisa diamati pada Gambar 4.




Gambar 4. Plot Data Pembedaan Pertama


Gambar 4 mengindikasikan bahwa kestasioneran data telah tercapai dikarenakan fluktuasi data ditemukan di sekitar nilai rata-rata. Namun untuk memperkuat asumsi ini, maka dilakukan kembali uji ADF pada data hasil pembedaan pertama. Berdasarkan hasil pengujian ADF, diperoleh bahwa nilai p -value ADF sebesar 0,01. Artinya nilai p -value lebih rendah daripada taraf signifikan $\alpha = 5\%$. Dengan demikian dapat ditarik kesimpulan bahwa data telah stasioner.

d) Menganalisa Plot ACF dan PACF

Karena kestasioneran data sudah terpenuhi, maka langkah selanjutnya adalah melakukan identifikasi orde p , d , q model melalui plot ACF dan PACF.



Gambar 5. Plot ACF Data Pembedaan Pertama



Gambar 6. Plot PACF Data Pembedaan Pertama


Ditinjau dari Gambar 5, nilai autokorelasi pada lag 4 dan lag 12 memotong batas signifikansi. Sementara pada Gambar 6, hanya lag 4 dan lag 16 yang memotong batas signifikansi, sedangkan lag 12 hanya mendekati batas signifikansi. Hal ini mengindikasikan bahwa terdapat pola musiman pada data, yang diperkirakan memiliki periode musiman sebesar $S = 4$ atau $S = 12$, dengan S menyatakan panjang periode musiman.

Selanjutnya, jika dicermati kembali Gambar 5 dan Gambar 6, tidak tampak adanya lag non-musiman yang secara signifikan melewati batas signifikansi. Namun, lag ke-1 terlihat mendekati batas tersebut sebelum nilai autokorelasi menurun secara perlahan. Berdasarkan pola ini, dapat diusulkan model awal untuk uji coba menggunakan model *Moving Average* (MA) dengan orde




$q = 1$ dan model *Autoregressive* (AR) dengan orde $p = 1$. Dengan demikian diduga model awal yang terbentuk ARIMA (1,1,1).


Karena data diduga mengandung musiman, maka dilakukan pembedaan musiman untuk menghilangkan musiman pada data. Plot ACF dan PACF data hasil pembedaan musiman dapat dilihat pada Gambar 7 – 10.




Gambar 7. Plot ACF Data Pembedaan Musiman $S = 4$



Gambar 8. Plot PACF data Pembedaan Musiman $S = 4$



Gambar 9. Plot ACF Data Pembedaan Musiman $S = 12$



Gambar 10. Plot PACF Data Pembedaan Musiman $S = 12$

Berdasarkan plot ACF dan PACF di atas, untuk periode musiman $S = 4$ diperoleh model sementara ARIMA (1,1,1) (3,1,1)⁴. Sementara untuk periode musiman $S = 12$ diperoleh model sementara ARIMA (1,1,1) (1,1,1)¹².

e) Melakukan *Overfitting*

Setelah didapatkan model sementara, maka langkah selanjutnya adalah melakukan *overfitting* model, yaitu memunculkan kemungkinan model lainnya berdasarkan model sementara yang telah dibentuk. Proses ini dilakukan dengan cara mengubah orde p , q , P , dan Q , namun orde yang diubah tidak melebihi orde pada model sementara [14]. Melalui proses ini diperoleh 48 kombinasi model. Namun, hanya 45 model yang dapat dilanjutkan ke tahap penaksiran dan pengujian. Dua model diantaranya tidak dapat dianalisis lebih lanjut karena tidak mengandung parameter AR maupun MA sehingga tidak memiliki komponen yang dapat diestimasi. Sementara itu, satu model lainnya tidak dapat diproses karena struktur model yang terlalu kompleks.

4. Penaksiran dan Pengujian Parameter

Tahap selanjutnya adalah melakukan penaksiran dan pengujian parameter model. Pada tahapan ini digunakan hipotesis:

H_0 : parameter model tidak signifikan

H_1 : parameter model signifikan

Kriteria pengujian yaitu apabila,

$$|t_{hitung}| > t_{\frac{\alpha}{2}, df=n-k}$$

dengan n merupakan banyaknya data dan k merupakan banyaknya parameter. Jika setiap parameter model signifikan, maka model tersebut dapat dipakai dalam peramalan.

Tabel 2. Rangkuman Penaksiran dan Pengujian Parameter Model

No.	Model	Parameter	t-hitung	t-tabel
1.	(1,1,1)(1,1,0) ⁴	AR 1	7,2602	1,9909
		MA 1	-21,4183	
		SAR 1	-5,0051	
2.	(1,1,1)(0,1,1) ⁴	AR 1	3,1207	1,9909
		MA 1	-5,5760	
		SMA 1	-9,5526	
3.	(1,1,1)(0,1,0) ⁴	AR 1	5,9932	1,9905
		MA 1	-27,1703	
4.	(0,1,0)(3,1,0) ⁴	SAR 1	-10,7599	1,9909
		SAR 2	-8,1671	
		SAR 3	-3,8867	
5.	(0,1,0)(2,1,1) ⁴	SAR 1	-4,2894	1,9909
		SAR 2	-3,9106	
		SMA 1	-3,3204	
6.	(0,1,0)(2,1,0) ⁴	SAR 1	-9,7937	1,9905
		SAR 2	-7,1836	
7.	(0,1,0)(1,1,1) ⁴	SAR 1	-2,1276	1,9905
		SMA 1	-5,1249	
8.	(0,1,0)(1,1,0) ⁴	SAR 1	-5,5556	1,9901
9.	(0,1,0)(0,1,1) ⁴	SMA 1	-10,8373	1,9901
10.	(1,1,1)(1,1,0) ¹²	AR 1	13,2435	1,9909
		MA 1	-13,3070	
		SAR 1	-3,0885	
11.	(1,1,1)(0,1,1) ¹²	AR 1	2,7272	1,9909
		MA 1	-4,1467	
		SMA 1	-2,7942	
12.	(0,1,0)(1,1,0) ¹²	SAR 1	-3,3801	1,9901
13.	(0,1,0)(0,1,1) ¹²	SMA 1	-3,2361	1,9901

Tabel 2 menunjukkan bahwa dari 45 kombinasi awal, terdapat 13 model yang memenuhi kriteria pengujian.

5. Pemeriksaan Diagnostik

Pemeriksaan diagnostik bertujuan untuk melihat model yang paling cocok digunakan untuk peramalan. Beberapa asumsi yang harus dipenuhi, yaitu *white noise* dan normalitas. Pengujian asumsi *white noise* dilakukan dengan menggunakan uji Ljung Box dengan hipotesis sebagai berikut:

H_0 : residual memenuhi *white noise*

H_1 : residual tidak memenuhi *white noise*

Kriteria pengujian yaitu tolak H_0 apabila nilai *p-value* lebih kecil dari α dengan α sebesar 5%.

Tabel 3. Uji Ljung Box

No.	Model	<i>p-value</i>
1.	(1,1,1)(0,1,1) ⁴	0,0649
2.	(0,1,0)(3,1,0) ⁴	0,7583
3.	(0,1,0)(2,1,1) ⁴	0,8436
4.	(0,1,0)(2,1,0) ⁴	0,1707
5.	(0,1,0)(1,1,1) ⁴	0,0601



No.	Model	<i>p-value</i>
6.	(1,1,1)(1,1,0) ¹²	0,0831
7.	(1,1,1)(0,1,1) ¹²	0,1831
8.	(0,1,0)(1,1,0) ¹²	0,1021
9.	(0,1,0)(0,1,1) ¹²	0,1528

Berdasarkan Tabel 3, terdapat 9 model yang memenuhi kriteria pengujian. Setelah dilakukan uji asumsi *white noise*, selanjutnya dilakukan uji asumsi normalitas menggunakan uji Kolmogorov Smirnov dengan hipotesis sebagai berikut:

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Kriteria pengujian yaitu tolak H_0 apabila nilai *p-value* lebih kecil dari α dengan α sebesar 5%.

Tabel 4. Uji Kalmogorov Smirnov

No.	Model	<i>p-value</i>
1.	(1,1,1)(0,1,1) ⁴	0,3602
2.	(0,1,0)(3,1,0) ⁴	0,7512
3.	(0,1,0)(2,1,1) ⁴	0,8899
4.	(0,1,0)(2,1,0) ⁴	0,2534
5.	(0,1,0)(1,1,1) ⁴	0,8611
6.	(1,1,1)(1,1,0) ¹²	0,1152
7.	(1,1,1)(0,1,1) ¹²	0,2703
8.	(0,1,0)(1,1,0) ¹²	0,0528
9.	(0,1,0)(0,1,1) ¹²	0,1072

Tabel 4 mengindikasikan bahwa kesembilan model yang diuji memenuhi asumsi normalitas. Setelah semua asumsi dalam pemeriksaan diagnostik dipenuhi, maka selanjutnya dilakukan seleksi pemilihan model terbaik

6. Pemilihan Model Terbaik

Model terbaik yang digunakan untuk peramalan adalah model yang memiliki nilai MSE terkecil [15]. Nilai MSE dari setiap model terpilih dapat dilihat pada Tabel 5.

Tabel 5. Perbandingan MSE Model

No.	Model	MSE
1.	(1,1,1)(0,1,1) ⁴	676.089.288
2.	(0,1,0)(3,1,0) ⁴	630.297.457
3.	(0,1,0)(2,1,1) ⁴	654.846.100
4.	(0,1,0)(2,1,0) ⁴	770.900.760
5.	(0,1,0)(1,1,1) ⁴	669.398.745
6.	(1,1,1)(1,1,0) ¹²	692.165.345
7.	(1,1,1)(0,1,1) ¹²	552.101.489
8.	(0,1,0)(1,1,0) ¹²	738.625.180
9.	(0,1,0)(0,1,1) ¹²	585.307.484

Berdasarkan Tabel 5, model 7 memiliki nilai MSE terkecil, yaitu sebesar 552.101.489. Nilai ini menunjukkan bahwa model tersebut memiliki tingkat kesalahan prediksi yang paling kecil dibandingkan model lainnya. Oleh karena itu, model *ARIMA* (1,1,1)(0,1,1)¹² dipilih sebagai model terbaik dan digunakan sebagai dasar untuk peramalan.

7. Peramalan

Model terbaik yang digunakan untuk peramalan yaitu *ARIMA* (1,1,1)(0,1,1)¹² dengan persamaan:

$$X_t = X_{t-12} + 1,6763X_{t-1} - 1,6763X_{t-13} - 0,6763X_{t-2} + 0,6763X_{t-14} + e_t - 0,8091e_{t-12} + 0,8173e_{t-1} + (0,8173)(0,8091)e_{t-13}$$

Hasil peramalan jumlah penumpang kereta api untuk bulan Oktober 2024 sampai September 2025 dapat dilihat pada Tabel 6.

Tabel 6. Hasil Ramalan Jumlah Penumpang Kereta Api

No.	Bulan	Hasil Ramalan
1.	Oktober 2024	149.799
2.	November 2024	151.818
3.	Desember 2024	192.338
4.	Januari 2025	168.059
5.	Februari 2025	160.915
6.	Maret 2025	159.679
7.	April 2025	160.464
8.	Mei 2025	172.933
9.	Juni 2025	179.685
10.	Juli 2025	165.625
11.	Agustus 2025	145.938
12.	September 2025	152.331

4. KESIMPULAN

Model terbaik untuk meramalkan jumlah penumpang PT. KAI Divisi Regional II Sumatera Barat yaitu $ARIMA(1,1,1)(0,1,1)^{12}$. Dari hasil peramalan, teridentifikasi jumlah penumpang kereta api tertinggi tercatat pada bulan Desember 2024 yaitu sebanyak 192.338 orang dan diikuti oleh Bulan Juni 2024 yaitu sebanyak 179.685. Peningkatan jumlah penumpang pada bulan-bulan tersebut dipengaruhi periode libur semester, hari libur Natal, dan tahun baru.

REFERENSI

- [1] S. Fatimah, *Pengantar Transportasi*. Ponorogo: Myria Publisher, 2019.
- [2] Awen, "Kereta Pariaman Ekspres, Transportasi Favorit Wisatawan Menuju Pantai di Sumbar," *suaraindo.id*.
- [3] H. Dwiatmoko, *Peran Transportasi Perkeretaapian Dalam Pembangunan Nasional Melalui Analisis Input-Output*. Jakarta Timur: Prenada Media, 2018.
- [4] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*. OTexts, 2018.
- [5] D. C. Montgomery, C. L. Jennings, and M. Kulahci, *Introduction to Time Series Analysis and Forecasting*. Canada: John Wiley & Sons. Inc, 2008.
- [6] S. Makridakis, S. C. Wheelwright, and V. E. McGee, *Metode dan Aplikasi Peramalan*, Edisi II. Jakarta: Erlangga, 1999.
- [7] Aswi and Sukana, *Analisis Deret Waktu: Teori dan Aplikasi*. Makassar: Andira Publisher, 2006.
- [8] W. W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*, Second Edition. Boston: Pearson Education, Inc, 2006.
- [9] K. E. ArunKumar, D. V Kalaga, Ch. M. S. Kumar, G. Chilkoor, M. Kawaji, and T. M. Brenza, "Forecasting the Dynamics of Cumulative COVID-19 Cases (Confirmed, Recovered and Deaths) for Top-16 Countries Using Statistical Machine Learning Models: Auto-Regressive Integrated Moving Average (ARIMA) and Seasonal Auto-Regressive Integrated Moving Average (SARIMA)," *Applied Soft Computing Journal*, vol. 103, pp. 1–26, 2021.
- [10] T. M. Wanjuki, A. Wagala, and D. K. Muriithi, "Forecasting Commodity Price Index of Food and Beverages in Kenya Using Seasonal Autoregressive Integrated Moving Average (SARIMA) Models," *European Journal of Mathematics and Statistics*, vol. 2, no. 6, pp. 50–63, Dec. 2021.
- [11] M. Triola, *Elementary Statistics Using Excel*, 6th Edition. Boston: Pearson, 2018.
- [12] W. Rachbini, A. H. Sumarto, and T. Evi, *Statistika Terapan: Pengolahan Data Time Series Menggunakan Eviews*. Serang: AA.Rizky, 2021.
- [13] Kementerian Kesehatan, *Peraturan Menteri Nomor 9 Tahun 2020 tentang Pedoman Pembatasan Sosial Berskala Besar dalam Rangka Percepatan Penanganan Corona Virus Disease 2019 (COVID-19)*. 2019.
- [14] A. Pankratz, *Forecasting With Univariate Box-Jenkins Models*. New York: John Wiley & Sons, 1983.
- [15] L. Arsyad, *Peramalan Bisnis*, Edisi Pertama. Yogyakarta: BPFE UGM, 1999.