



Prediksi Jumlah Penumpang *Light Rail Transit* (LRT) Palembang Menggunakan Metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA)

Aldi Saputra^{1*}, Dewi Sartika², Rendra Gustriansyah³

¹⁻³Universitas Indo Global Mandiri Palembang, Indonesia

*Penulis Korespondensi: royalealdi@gmail.com

Abstract. Mass transportation, particularly Light Rail Transit (LRT), plays a crucial role in supporting the modern-era mobility of Palembang's community. With the city's transit-oriented growth and high population density, the increased utilization of LRT presents challenges, such as congestion during holidays and special events, necessitating effective solutions to anticipate changes in passenger numbers. This study aims to design and implement a prediction model using the Seasonal Autoregressive Integrated Moving Average (SARIMA) method to anticipate and forecast the number of Palembang Light Rail Transit (LRT) passengers. By integrating seasonal components into time series analysis, this research focuses on developing a model that can accurately predict fluctuations in LRT passenger numbers, especially during special events or holiday seasons. The SARIMA method is expected to be an effective tool in public transportation management for planning operational sustainability and ensuring optimal services for the Palembang community. The prediction results using the parameter model $(0,1,1)(0,1,0)$ obtained an RMSE value of 57.68 and a Mean Absolute Percentage Error (MAPE) value of 16.69%; thus, the accuracy level achieved is 83.31%."

Keywords: Light Rail Transit; Passenger Demand; Prediction; SARIMA; Time Series.

Abstrak. Transportasi massal, terutama Light Rail Transit (LRT), memainkan peran dalam mendukung mobilitas masyarakat Palembang di era modern, dengan pertumbuhan kota berorientasi transit dan kepadatan tinggi, namun peningkatan penggunaan LRT menghadirkan tantangan, seperti penumpukan pada waktu libur dan acara khusus, memerlukan solusi efektif untuk mengantisipasi perubahan jumlah penumpang. Dalam penelitian ini bertujuan untuk merancang dan menerapkan model prediksi menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA) guna mengantisipasi dan memprediksi jumlah penumpang Light Rail Transit (LRT) Palembang. Metode SARIMA diharapkan dapat menjadi alat yang efektif dalam manajemen transportasi publik untuk merencanakan keberlanjutan operasional, dan memastikan pelayanan yang optimal bagi masyarakat Palembang. Hasil prediksi menggunakan model parameter $(0,1,1)(0,1,0)$ mendapatkan nilai RMSE sebesar 57.683 dan nilai MAPE sebesar 16.69% dengan demikian, tingkat akurasi yang didapat adalah sebesar 83.31%.

Kata Kunci: Angkutan Kereta Ringan; Deret Waktu; Permintaan Penumpang; Prediksi; SARIMA.

1. LATAR BELAKANG

Transportasi massal menjadi sangat penting untuk mendukung mobilitas masyarakat Palembang di era modern, karena infrastruktur perkotaan semakin berkembang dan globalisasi semakin meningkat. Sistem transportasi yang handal, efisien, dan berkelanjutan menjadi semakin penting karena urbanisasi yang terus meningkat dan kepadatan penduduk di pusat kota. Pemilihan metode transportasi yang tepat dapat berdampak pada kualitas hidup penduduk, produktivitas ekonomi, dan dampak lingkungan dari pertumbuhan kota.

Salah satu inisiatif transportasi cepat kota Palembang adalah Light Rail Transit (LRT). LRT memiliki 13 stasiun pada jalur transit cepat, yang mendorong pertumbuhan kota berorientasi transit dan kepadatan tinggi. Ini telah dipelajari untuk membandingkannya dengan kota-kota besar di negara maju yang telah menerapkan transportasi massal ini. LRT Palembang juga dapat menjadi komponen inisiatif angkutan cepat Kota Palembang dengan potensi tinggi

untuk angkutan cepat, terutama jika digabungkan dengan pertumbuhan penduduk, ekonomi yang berkembang, pembangunan kembali inti pusat kota dan rencana untuk pertumbuhan yang berkelanjutan (Ridho & Buchari, 2023).

LRT Palembang telah mengalami peningkatan penggunaan sejak diperkenalkan. Di waktu libur sering terjadinya penumpukan atau antrian orang yang hendak bepergian menggunakan LRT. Membuat manajemen LRT harus mencari solusi untuk mengatasinya. Masalah yang muncul adalah bagaimana manajemen LRT dapat mengetahui perubahan jumlah penumpang dan menanggapinya. Event khusus, seperti perayaan Tahun Baru, dan Cap Go Meh, dapat memicu lonjakan penumpang yang besar. Oleh karena itu, penting untuk mempersiapkan dan memprediksinya dengan baik.

Beberapa penelitian terdahulu mengenai Prediksi transportasi massal telah dilakukan sebelumnya (Alfikrizal et al., 2020) dalam penelitiannya yang berjudul Simulasi Monte Carlo dalam Prediksi Jumlah Penumpang Angkutan Massal Bus Rapid Transit Kota Padang melakukan prediksi terhadap bus rapid transit. Hasil dari penelitian menunjukkan prediksi jumlah penumpang untuk tahun 2018 berdasarkan data tahun 2017 adalah 2182242 dengan rata-rata akurasi sebesar 82,43%, dan prediksi jumlah penumpang untuk tahun 2019 berdasarkan data tahun 2018 adalah 2689626 dengan rata-rata akurasi sebesar 83,80%. Kemudian, penelitian oleh (Utomo & Fanani, 2020) yang berjudul Peramalan Jumlah Penumpang Kereta Api di Indonesia Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA) melakukan prediksi jumlah penumpang kereta api. Hasil dari penelitian menunjukkan prediksi untuk tahun 2020 adalah 36.941.500 orang penumpang, dengan Perhitungan error didapatkan MSE sebesar 0,046875, dan didukung dengan nilai MAPE sebesar 6,26%. Metode SARIMA juga digunakan dalam penelitian (Inka Durrah et al., 2018) yang berjudul Peramalan Jumlah Penumpang Pesawat Di Bandara Sultan Iskandar Muda dengan Metode SARIMA (Seasonal Autoregressive Integrated Moving Average). Hasil dari penelitian ini adalah Jumlah penumpang pada bulan Januari terbanyak di Bandara Sultan Iskandar Muda diprediksikan akan terjadi pada Bulan Desember 2017 yaitu sebanyak 101484 jiwa. Sedangkan jumlah penumpang terendah diprediksikan akan terjadi pada Bulan Maret 2017 yaitu sebesar 87899 jiwa.

Prediksi jumlah penumpang LRT Palembang, pada penelitian ini akan menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA). Metode ini dipilih karena data yang digunakan menunjukkan pola seasonal. Selain itu, SARIMA dikenal baik dalam menangani variasi data yang terkait dengan perubahan musiman, seperti peningkatan jumlah penumpang selama periode waktu tertentu. Metode ini memprediksi data runtun waktu

dengan memperhitungkan pola musiman dan tren dalam data (triyani, 2022). Secara keseluruhan, SARIMA menyertakan model yang sesuai untuk kondisi musiman. Ini merupakan evolusi dari ARIMA, dengan penambahan komponen musiman, sehingga dapat menghasilkan performa yang lebih unggul ketika menghadapi situasi yang memerlukan pemikiran tentang aspek musiman. (Utomo & Fanani, 2020).

2. KAJIAN TEORITIS

Prediksi

Prediksi atau peramalan adalah upaya untuk menduga atau memperkirakan apa yang akan terjadi di waktu mendatang dengan menggunakan metode ilmiah yang didasarkan pada informasi yang relevan dari masa lalu (Wanto & Windarto, 2017). Manusia sering kali dapat memprediksi kejadian yang belum terjadi hanya dengan melihat pola kejadian yang sama berulang kali. Kemampuan prediksi ini merupakan hasil dari proses belajar dan pengalaman yang terakumulasi sepanjang hidup. Sebagai contoh, seseorang cenderung memprediksi kemungkinan hujan jika melihat langit mendung berdasarkan pengalaman masa lalu. Meskipun prediksi tidak selalu 100% akurat, namun kemampuan ini memberikan seseorang kesempatan untuk mempersiapkan diri dan merespons situasi dengan lebih baik.

Penumpang

Kata "passenger" berasal dari bahasa Inggris, yang dalam Bahasa Indonesia berarti "penumpang" menurut kamus Bahasa Inggris-Indonesia karya Echlos (2003). Pemahaman tentang istilah ini semakin diperkaya oleh definisi-definisi yang dikemukakan oleh sejumlah ahli. Martono (2007) memberikan definisi yang lebih spesifik, mengartikan "passenger" sebagai individu yang melakukan perjalanan menggunakan pesawat tanpa menjadi bagian dari kru pesawat tersebut. Soeprapto (2014) menambahkan dimensi keamanan dan keselamatan dalam definisinya, menyebutkan penumpang sebagai pengguna layanan transportasi udara yang memerlukan perhatian khusus terkait aspek tersebut (Sutarwati et al., 2016).

Light Rail Transit

Light Rail Transit (LRT) merupakan moda transportasi massal yang beroperasi di atas rel dan telah menjadi bagian integral dalam transformasi sistem transportasi perkotaan. LRT diperkenalkan sebagai solusi inovatif dalam bidang transportasi, dengan tujuan utama mengantar penumpang dari satu destinasi ke destinasi lainnya secara cepat, hemat, dan efektif (Nur Muhammad & Triana, 2017).

Berbeda dengan kendaraan pribadi yang sering menyebabkan kemacetan, LRT menawarkan alternatif yang lebih berkelanjutan bagi perkotaan yang padat. Memiliki kapasitas

yang besar dan waktu tempuh yang konsisten, LRT mampu secara signifikan mengurangi kepadatan lalu lintas yang kerap terjadi di kota-kota metropolitan. Keberadaan stasiun LRT yang dirancang dengan baik tidak hanya mempermudah mobilitas warga kota tetapi juga mendorong mereka untuk mengurangi ketergantungan pada kendaraan pribadi. Hal ini diharapkan dapat berkontribusi pada pengurangan beban lingkungan, peningkatan kualitas udara, dan peningkatan kemudahan mobilitas dalam jangka panjang di kota-kota besar. Dengan demikian, LRT tidak hanya menjadi sarana transportasi, tetapi juga menjadi elemen penting dalam pengembangan kota yang berkelanjutan.

3. METODE PENELITIAN

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan time series forecasting, yang memanfaatkan metode SARIMA untuk menganalisis pola historis jumlah penumpang LRT dan menghasilkan peramalan yang akurat. Populasi penelitian mencakup seluruh data jumlah penumpang LRT Sumatera Selatan, sedangkan sampel berupa data bulanan dari Agustus 2018 hingga Desember 2023. Data tersebut dibagi menjadi data training (Agustus 2018–Desember 2021) untuk membangun model dan data testing (Januari 2022–Desember 2023) untuk menguji performa model. Data penelitian diperoleh melalui teknik pengumpulan data sekunder dari Balai Pengelola LRT Sumatera Selatan, didukung dengan studi literatur dari jurnal, buku, makalah, dan sumber daring terkait analisis deret waktu dan metode SARIMA. Analisis data dilakukan melalui serangkaian tahapan, meliputi visualisasi deret waktu, uji kestasioneran menggunakan Box-Cox dan ADF, diferensiasi data hingga stasioner, identifikasi parameter melalui plot ACF dan PACF, uji signifikansi parameter dan residual, pemilihan model terbaik, serta peramalan menggunakan parameter terpilih. Kinerja model kemudian dievaluasi menggunakan nilai MAPE dan RMSE untuk menilai tingkat akurasi prediksi terhadap data aktual.

4. HASIL DAN PEMBAHASAN

Pengujian Tingkat kesalahan menggunakan RMSE

Pada tahap pengujian, tingkat kesalahan akan diukur menggunakan *Root Mean Square Error* (RMSE) sesuai dengan persamaan (2.9). Penggunaan *Root Mean Square Error* (RMSE) sebagai metrik evaluasi merupakan praktik umum dalam analisis prediksi dan model statistik. Dalam konteks analisis prediksi, RMSE digunakan untuk mengukur seberapa dekat prediksi model dengan nilai aktual yang diamati. Nilai RMSE yang rendah menunjukkan bahwa model memiliki tingkat kesalahan yang lebih kecil, yang berarti bahwa prediksi lebih dekat dengan

nilai aktual. Oleh karena itu, RMSE menjadi indikator kritis dalam mengevaluasi kualitas dan kinerja model prediksi.

Pada rumus RMSE, selisih antara data aktual dan data prediksi dipangkatkan dua untuk menghilangkan nilai negatif dan memberikan penekanan yang lebih besar pada kesalahan yang lebih besar. Kemudian, semua selisih tersebut dijumlahkan dan dibagi dengan jumlah total data. Setelah itu, akar kuadrat dari hasil rata-rata tersebut diambil untuk menghasilkan nilai RMSE. Berikut tabel 4.5 hasil perhitungan nilai RMSE:

Tabel 1. Tabel Hasil RMSE.

Bulan	Tahun	Nilai Prediksi (F)	Nilai Aktual (A)	SE
Januari	2022	234.137	193.990	1.611.781.609
Februari	2022	222.877	146.524	5.829.780.609
Maret	2022	248.558	195.847	2.778.449.521
April	2022	243.648	166.525	5.947.957.129
Mei	2022	279.119	352.840	5.434.785.841
Juni	2022	290.831	260.725	906.371.236
Juli	2022	233.815	286.978	2.826.304.569
Agustus	2022	221.231	254.043	1.076.627.344
September	2022	256.317	268.444	147.064.129
Oktober	2022	309.652	310.179	277.729
November	2022	304.914	294.964	99.002.500
Desember	2022	328.854	356.676	774.063.684
Januari	2023	365.372	316.521	2.386.420.201
Februari	2023	354.112	261.581	8.561.985.961
Maret	2023	379.793	279.621	10.034.429.584
April	2023	374.883	361.765	172.081.924
Mei	2023	410.354	336.260	5.489.920.836
Juni	2023	422.066	355.364	4.449.156.804
Juli	2023	365.050	370.468	29.354.724
Agustus	2023	352.466	345.592	47.251.876
September	2023	387.552	351.418	1.305.665.956
Oktober	2023	440.887	344.388	9.312.057.001

Bulan	Tahun	Nilai Prediksi (F)	Nilai Aktual (A)	SE
November	2023	436.149	342.228	8.821.154.241
Desember	2023	460.089	417.513	1.812.715.776
Rata-rata				3.327.277.533
RMSE				57.683

Melihat nilai-nilai RMSE dari tabel tersebut, dapat dikatakan bahwa angka-angka tersebut berkisar dari beberapa ribu hingga miliaran. Angka-angka sebesar ini mencerminkan besarnya variabilitas antara nilai prediksi dan aktual untuk masing-masing bulan dan tahun. Namun, yang lebih penting adalah nilai rata-rata RMSE, yang diberikan sebagai 57.683. Ini adalah nilai rata-rata kesalahan prediksi dari seluruh data yang dievaluasi.

Menurut penelitian yang dilakukan (Sinaga & Irawati, 2018), sebuah nilai RMSE yang rendah dapat dianggap sebagai indikator kinerja yang lebih baik, namun, hal ini juga harus disesuaikan dengan jenis data yang diprediksi. Artinya, nilai RMSE yang lebih rendah menunjukkan bahwa model prediksi memiliki kesesuaian yang lebih baik dengan data aktual, namun perlu juga memperhitungkan karakteristik data itu sendiri.

Dalam konteks penelitian ini, nilai RMSE sebesar 57.683 menunjukkan bahwa model prediksi memiliki tingkat kesalahan yang moderat. Meskipun tidak dapat dikategorikan sebagai nilai RMSE yang sangat rendah, hal itu tidak berarti bahwa model tersebut tidak berguna. Sebaliknya, nilai tersebut memberikan indikasi tentang seberapa baik model ini dalam memprediksi nilai aktual, dan bagaimana kesesuaian model ini dengan karakteristik data yang ada.

Pengujian Tingkat kesalahan menggunakan MAPE

Tahap selanjutnya melibatkan evaluasi tingkat kesalahan pada parameter model yang digunakan untuk peramalan menggunakan MAPE, Nilai MAPE yang dihitung dengan menggunakan persamaan (2.8). Berdasarkan rumus tersebut, selisih data aktual dengan peramalan dibagi dengan data aktual, kemudian nilainya di mutlakkan (absolut). Artinya MAPE akan selalu bernilai positif. Untuk mengaplikasikan rumus tersebut peneliti menggunakan data aktual yang bersumber pada Balai Pengelola Kereta Api Ringan Sumatera Selatan, dari data yang didapatkan data berisikan data aktual per Agustus 2018 sampai dengan Desember 2023. Data aktual yang diperoleh dapat dilihat pada

Setelah mendapatkan data aktual dan hasil prediksi jumlah penumpang LRT, akan dihitung nilai MAPE nya dengan menggunakan Rstudio, Kode untuk menghitungnya dapat dilihat pada gambar.

```

# Data nilai prediksi (F) dan nilai aktual (A)
nilai_prediksi <- c(234.137, 222.877, 248.558, 243.648, 279.119, 290.831,
233.815, 221.231, 256.317, 309.652, 304.914, 328.854, 365.372, 354.112,
379.793, 374.883, 410.354, 422.066, 365.050, 352.466, 387.552, 440.887,
436.149, 460.089)

nilai_aktual <- c(193.990, 146.524, 195.847, 166.525, 352.840, 260.725,
286.978, 254.043, 268.444, 310.179, 294.964, 356.676, 316.521, 261.581,
279.621, 361.765, 336.260, 355.364, 370.468, 345.592, 351.418, 344.388,
342.228, 417.513)

# Fungsi untuk menghitung MAPE
hitung_mape <- function(y_aktual, y_pred) {
  return(abs((y_aktual - y_pred) / y_aktual) * 100)
}

mape_per_baris <- hitung_mape(nilai_aktual, nilai_prediksi)

# Fungsi untuk menghitung hasil_mape
hasil_mape <- data.frame(nilai_prediksi, nilai_aktual, mape_per_baris)
cat("Data MAPE per Baris:\n")
print(hasil_mape)

# Fungsi untuk menghitung rata_rata_mape
rata_rata_mape <- mean(hasil_mape$mape_per_baris)
cat("Rata-rata MAPE:", rata_rata_mape, "\n")

```

Gambar 1. Kode-R pada Rstudio untuk mencari nilai MAPE.

Berikut adalah contoh pengerjaan manual dari rumus diatas dilakukan pada baris pertama.

$$\begin{aligned}
 &= \frac{(Data\ aktual - Hasil\ Prediksi)}{Data\ Aktual} \\
 &= \frac{(193.990 - 234.137)}{193.990} \\
 &= \frac{(-40.147)}{193.990} \\
 &= -0.2069
 \end{aligned}$$

Setelah mendapatkan nilai error, langkah selanjutnya adalah mengubah nilai tersebut menjadi persentase. Proses ini dilakukan untuk setiap baris dari bulan Januari 2022 hingga Desember 2023. Dengan cara ini, kesalahan prediksi untuk setiap bulan dapat dievaluasi secara relatif terhadap nilai aktual yang bersangkutan.

Proses manual ini memberikan pemahaman yang lebih mendalam tentang kualitas prediksi dan memungkinkan untuk mengidentifikasi pola atau tren dalam kesalahan prediksi dari waktu ke waktu. Selain itu, melakukan pengerjaan manual membantu untuk memverifikasi keakuratan perhitungan dan mengidentifikasi kemungkinan kesalahan dalam proses peramalan. Dengan melibatkan langkah-langkah yang jelas dan terstruktur, dapat memastikan konsistensi dan keandalan dalam penggunaan rumus perhitungan MAPE. Pada Tabel 4.6 menampilkan nilai prediksi, nilai aktual dan nilai MAPE yang diperoleh untuk periode Januari 2022 hingga Desember 2023.

Tabel 2. Hasil Perhitungan MAPE.

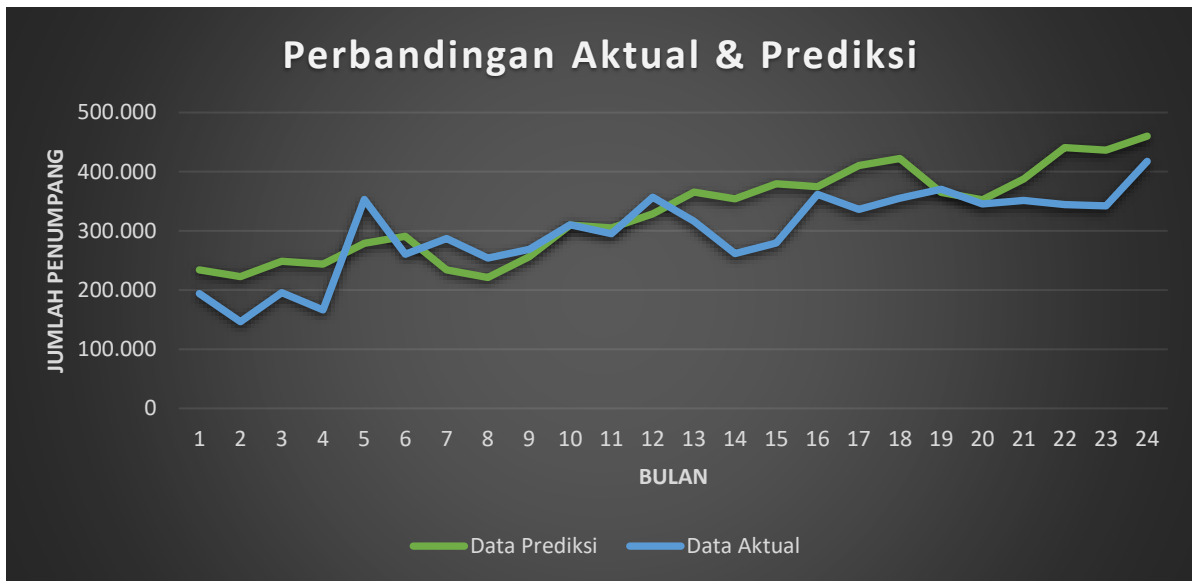
Bulan	Tahun	Nilai Prediksi (F)	Nilai Aktual (A)	MAPE
Januari	2022	234.137	193.990	20.69%
Februari	2022	222.877	146.524	52.11%
Maret	2022	248.558	195.847	26.91%
April	2022	243.648	166.525	46.31%
Mei	2022	279.119	352.840	20.89%
Juni	2022	290.831	260.725	11.54%
Juli	2022	233.815	286.978	18.52%
Agustus	2022	221.231	254.043	12.91%
September	2022	256.317	268.444	4.51%
Oktober	2022	309.652	310.179	0.17%
November	2022	304.914	294.964	3.37%
Desember	2022	328.854	356.676	7.80%
Januari	2023	365.372	316.521	15.43%
Februari	2023	354.112	261.581	35.37%
Maret	2023	379.793	279.621	35.82%
April	2023	374.883	361.765	3.62%
Mei	2023	410.354	336.260	22.03%
Juni	2023	422.066	355.364	18.77%
Juli	2023	365.050	370.468	1.46%
Agustus	2023	352.466	345.592	1.98%
September	2023	387.552	351.418	10.28%
Oktober	2023	440.887	344.388	28.02%
Bulan	Tahun	Nilai Prediksi (F)	Nilai Aktual (A)	MAPE
November	2023	436.149	342.228	27.44%
Desember	2023	460.089	417.513	10.19%
		Rata-rata		16.69%

Pada Tabel hasil perhitungan MAPE untuk setiap bulan dan tahun ditampilkan dengan detail. MAPE adalah metrik evaluasi yang penting dalam mengevaluasi keakuratan model prediksi. Hasil perhitungan MAPE untuk masing-masing bulan menunjukkan tingkat kesalahan relatif dari prediksi model terhadap nilai aktual.

Dari Tabel nilai MAPE dihasilkan dengan menghitung rata-rata dari setiap perhitungan MAPE tersebut, sehingga menghasilkan nilai MAPE sebesar 16.69%. Ini berarti secara rata-rata, prediksi model memiliki kesalahan sebesar 16.69% dari nilai aktual. Dari nilai MAPE ini, tingkat akurasi model dapat diestimasi sebesar 83.31%, yang dihitung dengan mengurangi nilai MAPE dari 100%, atau $100\% - 16.69\% = 83.31\%$. Hal ini menunjukkan bahwa model prediksi memiliki tingkat akurasi yang cukup baik dalam memprediksi nilai variabel yang diamati.

Analisis ini menggambarkan tingkat error prediksi untuk berbagai periode, memberikan wawasan tentang kualitas dan keandalan model prediksi. Contoh, bulan Mei 2022 memiliki error 20.89%, menandakan ketidakakuratan yang signifikan. Sementara Juni 2022 memiliki error 11.54%, menunjukkan prediksi yang relatif akurat. Oktober 2022 menunjukkan error hanya 0.17%, menandakan prediksi yang sangat baik. Namun, Januari 2023 memiliki error 15.43%, menunjukkan deviasi yang cukup besar. Terakhir, Maret 2023 memiliki error 35.82%, menunjukkan prediksi yang jauh dari nilai aktual. Rata-rata error prediksi dari seluruh data adalah 16.69%, yang merupakan indikator kualitas keseluruhan dari model prediksi.

Pada Gambar terlihat perbandingan nilai aktual dan prediksi yang sangat penting untuk evaluasi model. Hasil perbandingan tren menunjukkan konsistensi antara garis prediksi dan garis aktual dari bulan ke bulan, yang menandakan kemampuan model untuk mengikuti dan mereproduksi tren dengan baik. Perbedaan yang minimal antara kedua garis tersebut memberikan gambaran akurasi model, di mana deviasi yang lebih kecil menunjukkan prediksi yang lebih baik. Dengan kata lain, semakin dekat garis prediksi dengan garis aktual, semakin akurat model dalam memprediksi nilai sebenarnya. Hal ini membantu pengguna model untuk mengevaluasi kinerja model secara visual dan membuat keputusan yang tepat berdasarkan hasil prediksi yang diberikan.



Gambar 2. Plot Perbandingan Data Aktual Dan Prediksi.

4. KESIMPULAN DAN SARAN

Berdasarkan pembahasan yang telah dilakukan, dapat disimpulkan bahwa penelitian ini berhasil memprediksi jumlah penumpang LRT Palembang menggunakan metode Seasonal Autoregressive Integrated Moving Average. Dengan nilai RMSE sebesar 57.68 dan nilai MAPE sebesar 16.69%, hasil prediksi tersebut dapat dianggap baik karena berada pada tingkat nilai Range MAPE 10-20%. Dengan demikian, tingkat akurasi prediksi diperoleh sebesar 83.31%.

DAFTAR REFERENSI

- Aktivani, S. (2021). *Uji stasioneritas data inflasi Kota Padang periode 2014–2019*.
- Alfikrizal, K., Defit, S., & Yunus, Y. (2020). Simulasi Monte Carlo dalam prediksi jumlah penumpang angkutan massal Bus Rapid Transit Kota Padang. *Jurnal Informatika Ekonomi Bisnis*, 3(2). <https://doi.org/10.37034/infec.v3i2.72>
- Anggraeni, D., Muharom, L. A., & Hadi, A. F. (2014). *Prosiding Seminar Nasional Matematika*.
- Azman Maricar, M. (2019). *Analisa perbandingan nilai akurasi moving average dan exponential smoothing untuk sistem peramalan pendapatan pada perusahaan XYZ*.
- Desvina, A. P. (2014). Penerapan metode Box–Jenkins untuk memprediksi jumlah mahasiswa Universitas Islam Negeri Suska Riau. *Jurnal Sains, Teknologi dan Industri*, 12(1), 80–89.
- Ervina, M. E., Silvi, R., & Wisisono, I. R. N. (2018). Peramalan jumlah penumpang kereta api di Indonesia dengan resilient back-propagation (Rprop) neural network. *Jurnal Matematika MANTIK*, 4(2), 90–99. <https://doi.org/10.15642/mantik.2018.4.2.90-99>

- Funtika Saputri, A., & Hoyyi, A. (2017). Prediksi jumlah penumpang kereta api menggunakan model variasi kalender dengan deteksi outlier (Studi kasus: PT Kereta Api Indonesia DAOP IV Semarang). *Jurnal Gaussian*, 6(3), 281–289. <http://ejournal-s1.undip.ac.id/index.php/gaussian>
- Gio, P. U. (2016). *Belajar statistika dengan R (disertai beberapa contoh perhitungan manual)*. www.olahdatamedan.com
- Inka Durrah, F., Parhusip, T. P., & Rusyana, A. (2018). Peramalan jumlah penumpang pesawat di Bandara Sultan Iskandar Muda dengan metode SARIMA. *Journal of Data Analysis*, 1(1). <https://doi.org/10.24815/jda.v1i1.11847>
- Istanto, L., & Fauzie, S. (2014). *Analisis dampak pembayaran non-tunai terhadap jumlah uang beredar di Indonesia*.
- Istiarini, R., & Sukanti. (2012). *Rumus uji-t*.
- Khesya, N. (2021). *Mengenal flowchart dan pseudocode dalam algoritma dan pemrograman*. <https://doi.org/10.31219/osf.io/syjn5>
- Lailiyah, R. R., & Agustiani, R. (2022a). Peramalan jumlah penumpang LRT Sumsel dengan metode exponential smoothing. *Diophantine*. <https://doi.org/10.33369/diophantine.v1i1.23994>
- Lailiyah, R. R., & Agustiani, R. (2022b). Peramalan jumlah penumpang LRT Sumsel dengan metode exponential smoothing. *Diophantine*. <https://doi.org/10.33369/diophantine.v1i1.23994>
- Lestari, N., & Wahyuningsih, N. (2012). Peramalan kunjungan wisata dengan pendekatan model SARIMA (Studi kasus: Kusuma Agrowisata). *Jurnal Sains dan Seni ITS*, 1.
- Lubis, R. M. F., Situmorang, Z., & Rosnelly, R. (2021). Autoregressive integrated moving average (ARIMA–Box Jenkins) pada peramalan komoditas cabai merah di Indonesia. *Jurnal Media Informatika Budidarma*, 5(2), 485. <https://doi.org/10.30865/mib.v5i2.2927>
- Lusiani, A., & Habinuddin, E. (2011). Pemodelan autoregressive integrated moving average (ARIMA) curah hujan di Kota Bandung.
- Mahfud Al, A., Kurniasari, D., & Mustofa Usman. (2020). Peramalan data time series seasonal menggunakan metode analisis spektral. *Jurnal Siger Matematika*, 1(1).
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and applications* (3rd ed.). Wiley.
- Minarni, O., & Aldyanto, F. (2016). Prediksi jumlah produksi roti menggunakan metode logika fuzzy (Studi kasus: Roti Malabar Bakery). *Jurnal Teknoif*, 4(2).
- Nabillah, I., & Ranggadara, I. (2020). Mean absolute percentage error untuk evaluasi hasil prediksi komoditas laut. *JOINS (Journal of Information System)*, 5(2), 250–255. <https://doi.org/10.33633/joins.v5i2.3900>
- Nugroho, K. (2016). *Model analisis prediksi menggunakan metode fuzzy time series*.
- Nur Muhammad, A., & Triana, S. (2017). *Analisis teknis operasional light rail transit Kota Bandung*.
- Rahmalina, W. (2020). Peramalan indeks kekeringan Kelayang menggunakan metode SARIMA dan SPI. <https://doi.org/10.35313/potensi.v22i1.1824>

- Rakhmadi Pratama, A. (2022). Price prediction using ARIMA model of monthly closing price of Bitcoin. *Journal of Statistics and Data Science*. <https://doi.org/10.33369/jsds.v1i2.22689>
- Ridho, M. F., & Buchari, E. (2023). Transportasi Light Rail Transit (LRT) Palembang Sumatera Selatan berdampak lingkungan dan pengembangan usaha perkotaan sektor non fare box. *Jurnal Bearing*, 8(1). <https://doi.org/10.32502/jbearing.v8i1.6268>
- Sinaga, H., & Irawati, N. (2018). Perbandingan double moving average dengan double exponential smoothing pada peramalan bahan medis habis pakai.
- Soeprajogo, M. P., & Ratnaningsih, N. (2020). Perbandingan dua rata-rata uji-t.
- Sutarwati, S., Hardiyana, & Karolina, N. (2016). Tanggung jawab pengusaha angkutan udara terhadap penumpang maskapai Garuda Indonesia yang mengalami keterlambatan penerbangan di Bandara Internasional Adi Soemarmo Solo.
- Tinungki, G. M. (2019). The analysis of partial autocorrelation function in predicting maximum wind speed. *IOP Conference Series: Earth and Environmental Science*, 235(1), 012097. <https://doi.org/10.1088/1755-1315/235/1/012097>
- Triyani, R. A. (2022). *Penerapan metode seasonal autoregressive*.
- Utami, R., Atmojo, S., & Wijaya Putra. (2017). Implementasi metode triple exponential smoothing additive untuk prediksi penjualan alat tulis kantor (ATK) pada “X Stationery”.
- Utomo, P., & Fanani, A. (2020). Peramalan jumlah penumpang kereta api di Indonesia menggunakan metode SARIMA. *Jurnal Mahasiswa Matematika ALGEBRA*, 1(1).
- Vermaysha, A., & Nurmalitasari. (2023). Prediksi harga rumah di Kabupaten Karanganyar menggunakan metode regresi linear sistem informasi.
- Wanto, A., & Windarto, A. P. (2017). Analisis prediksi indeks harga konsumen berdasarkan kelompok kesehatan dengan menggunakan metode backpropagation. *Jurnal & Penelitian Teknik Informatika*, 2(2).
- Wibowo, A. (2022). *Analisis statistik dengan R*.