

Penentuan Strategi Peramalan Volume Barang Kiriman *outgoing* PT Pos Indonesia (Persero) KCU Purwokerto

Cindy Dwi Novita Sari¹, Ratih Windu Arini², Cindy Malinda Uscha³

^{1,2}Program Studi Teknik Logistik Kampus Kabupaten Banyumas, Universitas Telkom, Indonesia

³Program Studi Logistik Niaga-El, Politeknik Multimedia Nusantara, Tangerang, Indonesia

ARTICLE INFO

Article history:

Received: 10 November 2025

Revised: 17 Desember 2025

Accepted: 18 Desember 2022

Keywords:

Forecasting

ARIMA

Kiriman *outgoing*

Keterlambatan

ABSTRACT

Pengelolaan kiriman *outgoing* merupakan aspek penting dalam menjaga kelancaran proses distribusi di PT Pos Indonesia (Persero) KCU Purwokerto (POS KCU Purwokerto). Berdasarkan data internal, rata-rata keterlambatan (*overtime*) pengiriman mencapai 3.56% dari total volume kiriman dari September 2024 hingga September 2025. Oleh karena itu dibutuhkan sistem perencanaan berbasis analisis data melalui peramalan volume kiriman *outgoing* agar perusahaan dapat mengantisipasi lonjakan permintaan dan mengoptimalkan kapasitas armada serta tenaga kerja. Peramalan menggunakan pendekatan *time series* dengan metode *Naïve*, *Moving Average*, *Single Exponential Smoothing*, dan *Autoregressive Integrated Moving Average* (ARIMA). Hasil pengujian menunjukkan bahwa model ARIMA (2,1,1) merupakan model terbaik dengan tingkat kesalahan terkecil, yaitu *Mean Absolute Deviation* (MAD) sebesar 1867.87, *Mean Squared Error* (MSE) sebesar 7846634.40, dan *Mean Absolute Percentage Error* (MAPE) sebesar 7.001% dan sesuai dengan pola data permintaan historis. Hasil peramalan ini memberikan acuan yang akurat bagi manajemen dalam pengaturan kapasitas armada, penjadwalan distribusi, dan alokasi tenaga kerja sehingga dapat meminimalkan keterlambatan pengiriman akibat ketidakseimbangan antara kapasitas dan beban kerja serta meningkatkan efisiensi dan keberlanjutan operasional perusahaan di masa mendatang.

*Outgoing shipment management is a crucial aspect in maintaining the smooth distribution process at POS Purwokerto Branch. Based on internal data, the average delay (*overtime*) in shipments reached 3.56% of the total shipment volume from September 2024 to September 2025. Therefore, a data analysis-based planning system is needed through forecasting the volume of outgoing shipments so that the company can anticipate spikes in demand and optimize fleet and workforce capacity. Forecasting uses a time series approach with the *Naïve*, *Moving Average*, *Single Exponential Smoothing*, and *Autoregressive Integrated Moving Average* (ARIMA) methods. The test results show that the ARIMA (2,1,1) model is the best model with the smallest error rate, namely a *Mean Absolute Deviation* (MAD) of 1867.87, a *Mean Squared Error* (MSE) of 7846634.40, and a *Mean Absolute Percentage Error* (MAPE) of 7.001% and is in accordance with historical demand data patterns. The forecast results provide an accurate reference for management in managing fleet capacity, distribution scheduling, and workforce allocation so as to minimize delivery delays due to imbalances between capacity and workload and increase the efficiency and sustainability of the company's operations in the future.*

Corresponding Author:

Cindy Dwi Novita Sari

Program Studi Teknik Logistik Kampus Kabupaten Banyumas, Universitas Telkom, Indonesia

Jl. DI Panjaitan No.128, Karangreja, Purwokerto Kidul, Kec. Purwokerto Sel., Kabupaten Banyumas, Jawa Tengah 53147, Indonesia

Email: ratiharini@telkomuniversity.ac.id

PENDAHULUAN

Permasalahan keterlambatan pengiriman tidak hanya merupakan persoalan teknis, tetapi juga berdampak langsung pada kepuasan dan loyalitas pelanggan. Survei menunjukkan bahwa 34% pelanggan kecewa ketika paket tiba terlambat, sedangkan 21% lainnya menilai respons layanan saat terjadi kendala masih lambat (Nevi Fitria Aini, Deden Darmansyah, Rahmad Apriyono, Ramdhani & Prastyo, 2025). Penelitian lain menyebutkan bahwa pelanggan cenderung berpindah ke penyedia jasa lain setelah dua kali mengalami pengalaman negatif berturut-turut (Maqbulla Arochman, 2021). Selain itu, ketidaksesuaian status pengiriman di aplikasi dengan kondisi lapangan juga dapat menurunkan kepercayaan pelanggan (Dadang Surya Kencana, Sipon Al Munir, 2025). Penelitian tersebut hanya menjelaskan dampak pengukuran kepuasan pelanggan terhadap perbedaan pengiriman dan bukan merupakan upaya perbaikan. Penelitian ini bertujuan untuk meramalkan permintaan kiriman barang *outgoing* POS KCU Purwokerto dengan menentukan metode peramalan terbaik dari empat metode *time series* terhadap permintaan siklus.

Pengiriman *outgoing* merupakan salah satu proses penting di POS KCU Purwokerto karena menjadi tahap akhir sebelum barang diteruskan ke kantor tujuan. Proses ini meliputi penerimaan barang, penyortiran, pemindaian, pemberian kode, hingga penyerahan ke bagian distribusi. Data internal mencatat rata-rata keterlambatan (*overtime*) pengiriman sekitar 976 paket atau 3.56 % per bulan dari total volume kiriman dari September 2024 sampai September 2025. Kondisi ini memerlukan perhatian serius karena dapat memengaruhi kepuasan pelanggan sekaligus citra Pos Indonesia sebagai penyedia layanan kurir nasional. Selain itu, volume kiriman *outgoing* juga berfluktuasi mengikuti musim, misalnya saat libur panjang, bulan Ramadan, dan periode promosi besar *e-commerce*. Dinamika tersebut menuntut adanya sistem peramalan yang akurat agar kapasitas pengiriman dapat diatur secara tepat dan efisien.

Keterlambatan pengiriman sering kali disebabkan oleh lonjakan permintaan yang tidak diimbangi dengan ketersediaan armada dan tenaga kerja. Armada yang terbatas serta alokasi karyawan yang kurang memadai membuat perusahaan kesulitan memenuhi kebutuhan operasional pada 18 periode puncak, sehingga distribusi mengalami hambatan. Kondisi ini menunjukkan perlunya sistem perencanaan berbasis analisis data peramalan yang mampu memprediksi dan mengantisipasi perubahan permintaan, sehingga kapasitas armada, kebutuhan sumber daya manusia, dan strategi operasional dapat ditentukan dengan lebih tepat (Rahmayani, R., Handayani, S., Telaumbanua, A., Fitrah, A., & Rayhan, 2025). Peramalan (*forecasting*) menjadi instrumen penting karena dapat memproyeksikan kebutuhan di masa mendatang dengan memanfaatkan data historis.

Forecasting memungkinkan perusahaan menyesuaikan kapasitas armada, mengalokasikan sumber daya manusia, serta merancang jadwal operasional dengan lebih efektif. *Forecasting* sendiri didefinisikan sebagai proses memperkirakan kebutuhan atau peristiwa masa depan melalui model sistematis (Barry Render, 2001). Ketidaktepatan estimasi berisiko menimbulkan konsekuensi biaya, estimasi berlebihan meningkatkan beban *inventory*, sedangkan estimasi terlalu rendah dapat memicu keterlambatan dan kehilangan pelanggan (Nasapi, A., Surarso, B., & Cahyo, 2014).

Dengan demikian, penerapan analisis peramalan pada data kiriman *outgoing* di POS KCU Purwokerto menjadi langkah strategis untuk meminimalkan potensi keterlambatan, mengantisipasi lonjakan volume, dan menjaga kepuasan pelanggan. Hasil peramalan diharapkan mampu mendukung pengambilan keputusan manajerial, khususnya dalam penentuan kapasitas armada, alokasi tenaga kerja, serta penyusunan jadwal operasional yang lebih efisien sehingga kualitas layanan tetap terjaga di tengah persaingan industri logistik yang semakin ketat.

KAJIAN TEORI

Pengiriman barang merupakan bagian dari aktivitas distribusi yang bertujuan memindahkan produk dari titik produksi ke titik konsumsi dengan memperhatikan ketepatan waktu, keamanan, dan efisiensi biaya (Rushton, A., Croucher, P., & Baker, 2017). (Christopher, 2016) juga menjelaskan bahwa proses pengiriman barang adalah elemen penting dalam rantai pasok yang memastikan nilai produk dapat tersampaikan kepada pelanggan secara efektif. Pengiriman sangat erat kaitannya dengan ketepatan

waktu pengiriman yang dipengaruhi oleh salah satunya ketersediaan sumber daya. Untuk mengetahui bahwa sumber daya yang dibutuhkan untuk pengiriman telah sesuai, dibutuhkan perencanaan jumlah ketbutuhan sumber daya melalui peramalan. Dalam logistik *forecasting* berperan penting untuk memperkirakan volume, frekuensi, dan pola pengiriman barang di masa mendatang. Dengan adanya prediksi yang akurat, perusahaan jasa pengiriman dapat merencanakan kapasitas armada, tenaga kerja, jadwal distribusi, serta kebutuhan fasilitas pendukung sehingga kinerja operasional tetap efisien dan mampu memenuhi harapan pelanggan.

Peramalan merupakan suatu proses yang bertujuan untuk menentukan perkiraan kebutuhan pada periode mendatang dengan mempertimbangkan aspek jumlah, mutu, waktu, serta lokasi, sehingga dapat mendukung pemenuhan layanan secara tepat (Nasution, M. N., & Prasetyawan, 2008). Peramalan tersebut tidak bersifat spekulatif atau supranatural, melainkan dilakukan dengan pendekatan ilmiah menggunakan teknik kuantitatif dan kaidah matematis maupun statistika yang dapat dipertanggungjawabkan (Nachrowi, N. D., & Usman, 2004). Menurut (Herjanto, 2007) peramalan dapat dikategorikan berdasarkan panjangnya horizon waktu yang digunakan yaitu jangka panjang, jangka menengah dan jangka panjang.

Terdapat beberapa pola utama yang menjadi dasar pemilihan metode peramalan yaitu pola horizontal, musiman, siklis dan tren. Pola Musiman menggambarkan pergerakan data yang berulang secara periodik pada interval tertentu, misalnya triwulan, bulanan, atau mingguan. Pola ini biasanya dipengaruhi oleh faktor waktu seperti hari raya, musim belanja, atau periode tertentu dalam setahun. Metode yang banyak digunakan untuk pola musiman antara lain *Classical Decomposition*, *Census II*, *Winters Exponential Smoothing*, *Time Series Multiple Regression*, serta *Box-Jenkins*.

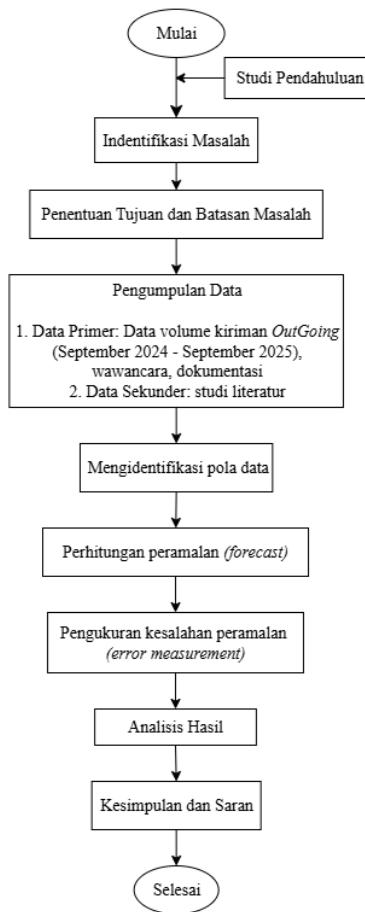
Penelitian ini menggunakan metode peramalan Naïve, *Moving Average* (MA), *Single Exponential Smoothing* (SES), dan ARIMA. Metode peramalan naïve berasumsi bahwa permintaan pada periode mendatang akan sama dengan permintaan pada periode sebelumnya. Artinya, hasil prediksi untuk periode berikutnya (F_{t+1}) dianggap setara dengan permintaan aktual pada periode sekarang (D_t). Pendekatan ini dikenal sebagai *naive approach*, yaitu model peramalan yang sederhana, objektif, serta efisien dari sisi biaya. Selain itu, metode ini juga menjadi salah satu teknik peramalan yang paling mudah diterapkan (Ritzman, L. P., Krajewski, L. J., & Malhotra, 2013). Metode *moving average* melakukan peramalan dengan perhitungan nilai rata-rata dari nilai aktual permintaan yang diperoleh dari data sebelumnya. Perhitungan dilakukan secara bergulir, artinya data lama digantikan dengan data terbaru. Teknik ini efektif untuk meratakan fluktuasi acak pada data yang relatif stabil tanpa tren atau musiman (Jacobs, F. R., & Chase, 2016; Sinulingga, 2013). Metode peramalan *exponential smoothing* dilakukan dengan menghitung nilai ramalan melalui penggabungan antara data aktual dan hasil peramalan periode sebelumnya. Pendekatan ini lebih responsif terhadap perubahan permintaan dibandingkan *moving average* karena menggunakan konstanta pemulusan (α) dengan nilai $0 \leq \alpha \leq 1$. Metode ARIMA adalah teknik peramalan yang diperkenalkan oleh Box dan Jenkins. Metode ARIMA dapat diterapkan pada data yang berpola tren ataupun musiman, namun data harus dalam kondisi stasioner sehingga sering diperlukan proses transformasi atau pembedaan terlebih dahulu (Octora, R., & Kuntoro, 2013).

Akurasi merupakan faktor penting dalam pemilihan metode peramalan karena hasil ramalan yang baik adalah yang memiliki nilai estimasi mendekati kondisi aktual (Mulyono, 2000). Kesalahan (*error*) dalam peramalan sendiri didefinisikan sebagai selisih nilai aktual dan nilai yang diperkirakan pada suatu periode. Oleh karena itu, kesalahan peramalan harus dipantau secara berkala untuk memastikan hasil ramalan tetap berada dalam batas wajar, dan apabila penyimpangan terlalu besar maka perlu dilakukan perbaikan metode atau parameter (Stevenson & Chuong, 2014). Beberapa ukuran akurasi yang umum digunakan adalah *Mean Absolut Deviation* (MAD), *Mean Square Error* (MSE), *Mean Absolute Percentage Error* (MAPE).

METODE PENELITIAN

Penelitian ini bertujuan untuk menentukan peramalan *outgoing* di POS KCU Purwokerto yang paling akurat untuk periode 1 tahun ke depan (2026). Penelitian dilakukan dengan melakukan studi pendahuluan mengenai identifikasi masalah dan studi literatur pendukung lainnya serta penentuan

tujuan dan batasan penelitian. Pengumpulan data dilakukan dengan observasi dan dokumentasi dari data primer seperti data proses bisnis juga data historis pengiriman *outgoing* periode September 2024 sampai September 2025 dan data sekunder seperti penelitian terdahulu yang mendukung penelitian ini. Berdasarkan data historis tersebut maka selanjutnya ditentukan pola permintaan yang ada agar metode peramalan dapat dipilih sesuai dengan pola data permintaan. Setelah pola data teridentifikasi, penelitian dilanjutkan dengan perhitungan peramalan menggunakan sejumlah metode yang sesuai dengan pola data yang sudah teridentifikasi. Hasil peramalan tersebut dievaluasi melalui pengukuran *error measurement* menggunakan indikator seperti *Mean Absolute Percentage Error* (MAPE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE) untuk menentukan metode yang paling akurat. Berikut merupakan *flowchart* tahapan penelitian yang dilakukan.

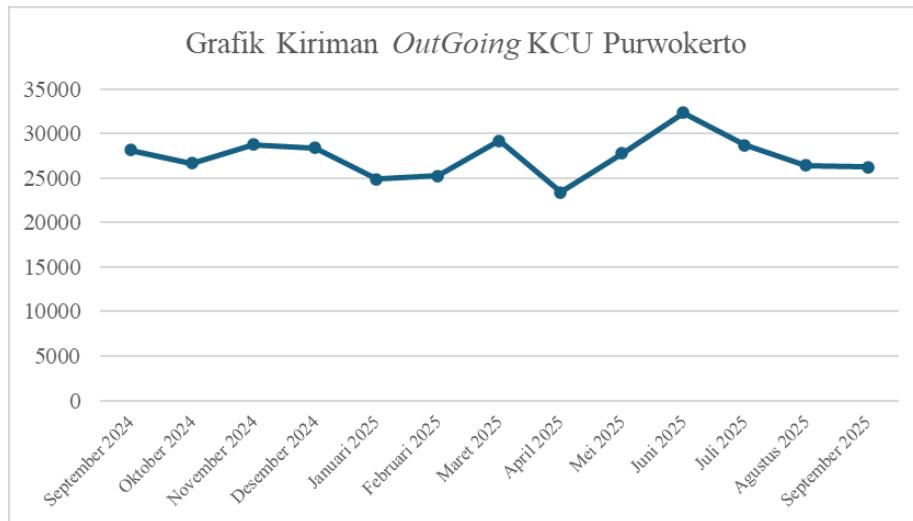


Gambar 1. *Flowchart* Penelitian

Tahap akhir penelitian difokuskan pada analisis hasil peramalan, di mana temuan yang diperoleh dari berbagai metode dibandingkan untuk melihat kecenderungan pola data serta tingkat ketepatannya. Analisis ini tidak hanya menampilkan proyeksi volume kiriman *outgoing* pada periode berikutnya, tetapi juga memberikan pemahaman mengenai metode mana yang mampu menghasilkan estimasi lebih mendekati kondisi aktual. Informasi tersebut menjadi dasar yang penting untuk mendukung pengelolaan kiriman *outgoing* secara lebih efisien, terutama dalam menghadapi fluktuasi permintaan yang terjadi pada periode tertentu. Dengan cara ini, hasil penelitian dapat memberikan arahan praktis bagi perusahaan dalam menjaga keandalan layanan sekaligus meningkatkan kualitas operasional di masa mendatang.

HASIL PENELITIAN DAN PEMBAHASAN

Data pada penelitian ini didapatkan dari catatan internal POS KCU Purwokerto mengenai volume kiriman *outgoing* yang berasal dari layanan ritel dan korporat dari bulan September 2024 hingga September 2025. Rentang waktu tersebut dipilih agar variasi musiman seperti lonjakan saat Ramadan, libur panjang, maupun periode promosi *e-commerce* dapat terlihat jelas. Data ini menjadi dasar untuk mengidentifikasi pola historis dan digunakan sebagai input utama dalam analisis peramalan (*forecasting*) volume kiriman pada periode selanjutnya.



Gambar 2. Grafik Volume Kiriman *outgoing* KCU Purwokerto

Sumber: PT Pos KCU Purwokerto, 2025

Volume kiriman *outgoing* POS KCU Purwokerto selama periode penelitian bergerak relatif stabil pada kisaran 24.000-30.000 kiriman per bulan. Namun, pada Juni 2025 terjadi lonjakan signifikan hingga mencapai 42.370 kiriman yang diduga dipengaruhi oleh faktor musiman, seperti libur panjang, momentum belanja daring berskala besar, maupun meningkatnya aktivitas pengiriman menjelang hari raya. Setelah periode tersebut, volume kiriman kembali menurun dan bergerak pada kisaran semula tanpa menunjukkan tren kenaikan maupun penurunan jangka panjang yang konsisten. Berdasarkan teori pola data *time series*, pola horizontal dengan fluktuasi acak seperti ini umumnya muncul pada data jangka pendek yang dipengaruhi faktor musiman. Dengan karakteristik tersebut, metode peramalan yang relevan untuk digunakan meliputi *Naïve Method*, *Moving Average*, *Single Exponential Smoothing*, dan *ARIMA (Autoregressive Integrated Moving Average)*. Keempat metode ini dipilih karena mampu menangkap pola data horizontal dengan fluktuasi musiman yang terlihat pada volume kiriman *outgoing* KCU Purwokerto.

Metode *Naïve* merupakan teknik peramalan paling sederhana dalam analisis deret waktu, di mana nilai ramalan periode berikutnya diasumsikan sama dengan nilai aktual pada periode sebelumnya. Peramalan dengan Metode *Naïve* dilakukan menggunakan bantuan perangkat lunak *Microsoft Excel*.

Tabel 1 menunjukkan ukuran ketepatan peramalan yang digunakan sebagai indikator akurasi model. Nilai SDE menunjukkan adanya penyimpangan standar yang relatif moderat antara hasil peramalan dan data aktual. Nilai MAD dan MSE menandakan adanya perbedaan antara hasil peramalan dan data aktual pada beberapa periode tertentu. Sementara itu, nilai MAPE yang berada di bawah ambang batas 20% menunjukkan *good forecast*. Hasil metode peramalan *Naïve* menunjukkan bahwa tingkat akurasi cukup baik, meskipun masih terdapat deviasi kecil antara hasil estimasi dan kondisi aktual pada sebagian periode pengamatan. Hasil

peramalan untuk periode kiriman outgoing Oktober 2025 – September 2025 ditunjukkan oleh Tabel 2.

Tabel 1. Metode Peramalan Naive

Bulan	Kiriman outgoing	Forecast	Error	Abs Error	Sqr Error	% Error	Abs % Error
Sept 2023	28174						
Okt 2024	26657	28174	-1517	1517	2301289	-5.691	5.691
Nov 2024	28748	26657	2091	2091	4372281	7.274	7.274
Des 2024	28416	28748	-332	332	110224	-1.168	1.168
Jan2025	24893	28416	-3523	3523	12411529	-14.153	14.153
Feb2025	25254	24893	361	361	130321	1.429	1.429
Mar 2025	29222	25254	3968	3968	15745024	13.579	13.579
Apr2025	23389	29222	-5833	5833	34023889	-24.939	24.939
Mei 2025	27790	23389	4401	4401	19368801	15.837	15.837
Juni 2025	32370	27790	4580	4580	20976400	14.149	14.149
Juli 2025	28684	32370	-3686	3686	13586596	-12.850	12.850
Agst 2025	26448	28684	-2236	2236	4999696	-8.454	8.454
Sept 2025	26237	26448	-211	211	44521	-0.804	0.804
<i>Error Measurement</i>				SDE	MAD	MSE	PE
				3407.984	2728.25	10672547.583	-1.316
							MAPE
							10.027%

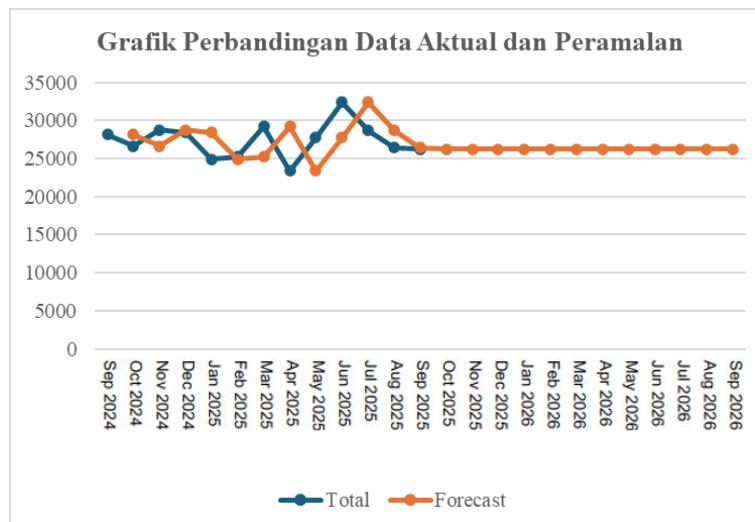
Tabel 2. Hasil Peramalan Metode Naïve Periode Oktober 2025 – September 2026

Bulan	Forecast	Bulan	Forecast
Okt 2025	2637	Apr 2026	2637
Nov 2025	2637	Mei 2026	2637
Des 2025	2637	Juni 2026	2637
Jan 2026	2637	Juli 2026	2637
Feb 2026	2637	Agst 2026	2637
Mar 2026	2637	Sept 2026	2637

Gambar 3 menunjukkan grafik perbedaan data aktual dan hasil peramalan dengan metode naïve memiliki kecenderungan yang serupa dengan jumlah data aktual pada periode awal pengamatan, namun mulai menunjukkan perbedaan setelah pertengahan tahun 2025. Pola garis peramalan terlihat konstan mulai Oktober 2025 hingga September 2027, dengan nilai yang stabil di sekitar 26237 per bulan. Kondisi ini terjadi karena metode Naïve hanya menggunakan nilai aktual periode terakhir sebagai dasar proyeksi, sehingga tidak mampu menyesuaikan terhadap perubahan pola data yang berfluktuasi. Pada periode lonjakan signifikan, seperti bulan Juni 2025, hasil peramalan tidak mampu menangkap peningkatan tajam yang terjadi, menyebabkan deviasi cukup besar antara data aktual dan hasil peramalan. Namun, pada periode dengan pergerakan yang relatif stabil, garis peramalan menunjukkan hasil yang cukup mendekati nilai aktual. Hal ini sesuai dengan karakteristik metode Naïve yang sederhana dan lebih tepat digunakan pada data dengan pola horizontal tanpa tren atau variasi ekstrem.

Penelitian ini menguji tiga variasi nilai *Moving Average* (MA), yaitu MA = 2, MA = 3, dan MA = 4 untuk membandingkan kinerja masing-masing model dalam menghasilkan tingkat akurasi peramalan yang paling tinggi. Rentang nilai MA yang relatif kecil dipilih karena pola data historis volume kiriman *outgoing* menunjukkan fluktuasi jangka pendek tanpa tren jangka panjang yang signifikan, sehingga periode perataan yang terlalu panjang justru dapat

mengaburkan variasi aktual dan menurunkan sensitivitas model terhadap perubahan data bulanan. Perhitungan dilakukan dengan bantuan perangkat lunak *Microsoft Excel* dan hasil *error* peramalan dari masing-masing nilai MA digunakan sebagai dasar untuk menentukan model terbaik. Hasil eror pada MA = 3 memiliki nilai kesalahan peramalan paling kecil dengan MAD sebesar 2.613,97, MSE sebesar 8.631.361,77, dan MAPE sebesar 9,59% yang menunjukkan bahwa model MA = 3 memiliki tingkat akurasi terbaik dibandingkan dua model lainnya.



Gambar 3. Grafik Perbandingan Data Aktual dan Peramalan Metode Naïve

Tabel 3. Metode Peramalan MA

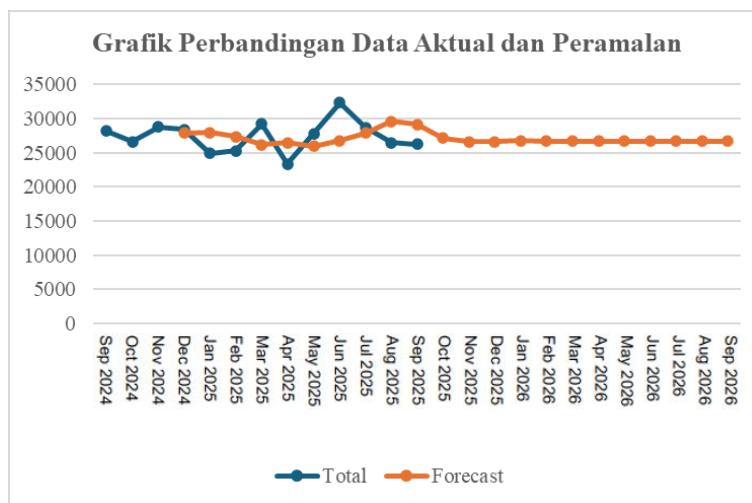
Bulan	Kiriman outgoing	Forecast	Error	Abs Error	Sqr Error	% Error	Abs % Error
Sept 2023	28174						
Okt 2024	26657						
Nov 2024	28748						
Des 2024	28416	27860	556	556,333	309506,778	1,958	1,958
Jan 2025	24893	27940	-3047	3047,333	9286240,444	-12,242	12,242
Feb 2025	25254	27352	-2098	2098,333	4403002,778	-8,309	8,309
Mar 2025	29222	26188	3034	3034,333	9207178,778	10,384	10,384
Apr 2025	23389	26456	-3067	3067,333	9408533,778	-13,114	13,114
Mei 2025	27790	25955	1835	1835	3367225	6,603	6,603
Juni 2025	32370	26800	5570	5569,667	31021186,778	17,206	17,206
Juli 2025	28684	27850	834	834,333	696112,111	2,909	2,909
Agst 2025	26448	29615	-3167	3166,667	10027777,778	-11,973	11,973
Sept 2025	26237	29167	-2930	2930,333	8586853,444	-11,169	11,169
Error Measurement				SDE	MAD	MSE	PE
				3085,781	2613,97	8631361,767	-1,775
							MAPE
							9,587

Tabel 4. Hasil Peramalan Metode MA Periode Oktober 2025 - September 2026

Bulan	Forecast	Bulan	Forecast
Okt 2025	27123	Apr 2026	26729
Nov 2025	26603	Mei 2026	26708
Des 2025	26654	Juni 2026	26716
Jan 2026	26793	Juli 2026	26717
Feb 2026	26683	Agst 2026	26714

Mar 2026	26710	Sept 2026	26716
----------	-------	-----------	-------

Berdasarkan perhitungan pada Tabel 3 dengan $MA = 3$ yang memproyeksikan rata-rata periode 3 bulan data historis terakhir menghasilkan pola peramalan yang lebih halus dan stabil karena setiap nilai ramalan merefleksikan tren jangka pendek dari data aktual. Metode *Moving Average* ($MA=3$) dapat dikatakan cukup efektif untuk menggambarkan pola data historis dengan penyimpangan yang relatif kecil karena masih berada di bawah 20%. Hasil peramalan dengan MA dapat dilihat pada Tabel 4.



Gambar 4. Grafik Perbandingan Data Aktual dan Peramalan Metode MA

Gambar 4 menunjukkan bahwa hasil peramalan menggunakan metode *Moving Average* ($MA=3$) memiliki pola yang relatif searah dengan data aktual, meskipun tidak sepenuhnya mampu menangkap fluktuasi tajam. Garis hasil peramalan bersifat lebih *smooth* dibandingkan dengan data aktual karena setiap nilai estimasi dihitung berdasarkan rata-rata tiga bulan terakhir. Garis peramalan tetap berada di sekitar nilai rata-rata data aktual, sehingga sangat baik dalam menggambarkan pola pergerakan volume kiriman *outgoing* pada kondisi stabil.

Metode *Exponential Smoothing* dalam penelitian ini menguji tiga variasi nilai α , yaitu $\alpha = 0.3$; $\alpha = 0.5$ dan $\alpha = 0.9$ untuk membandingkan kinerja peramalan pada kondisi α yang mendekati nol, nilai tengah, serta nilai yang mendekati satu. Perhitungan dilakukan dengan bantuan perangkat lunak *Microsoft Excel* dan hasil *error* peramalan dari masing-masing nilai α digunakan sebagai dasar untuk menentukan model terbaik. Nilai konstanta $\alpha = 0.3$ dipilih sebagai model terbaik setelah diuji karena menghasilkan tingkat kesalahan terkecil.

Tabel 3. Metode Peramalan ES

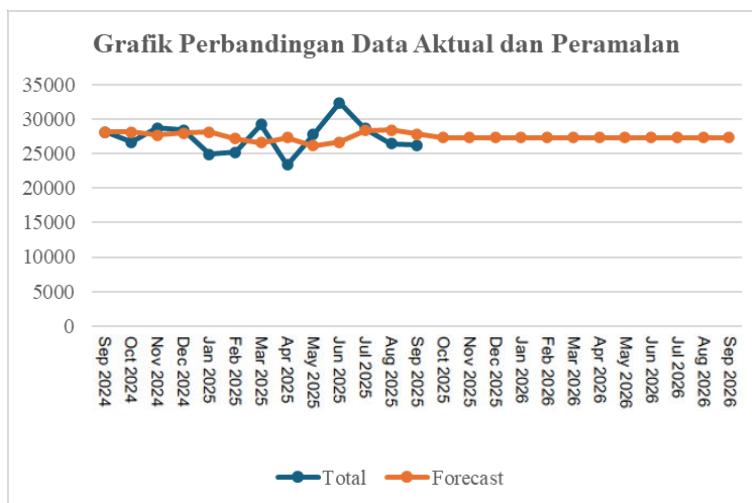
Bulan	Kiriman outgoing	Forecast	Error	Abs Error	Sqr Error	% Error	Abs % Error
Sept 2023	28174	28174					
Okt 2024	26657	28174	-1517	1517	2301289	-0.057	0.057
Nov 2024	28748	27719	1029.10	1029.10	1059046.810	3.580	3.580
Des 2024	28416	28028	388.370	388.370	150831.257	1.367	1.367
Jan 2025	24893	28144	-3251.141	3251.141	10569917.802	-13.060	13.060
Feb 2025	25254	27169	-1914.799	1914.799	3666454.062	-7.582	7.582
Mar 2025	29222	26594	2627.641	2627.641	6904496.752	8.992	8.992
Apr 2025	23389	27383	-3993.651	3993.651	15949251.209	-17.075	17.075
Mei 2025	27790	26185	1605.444	1605.444	2577450.585	5.777	5.777

Juni 2025	32370	26666	5703.811	5703.811	32533458.009	17.621	17.621
Juli 2025	28684	28377	306.668	306.668	94045.006	1.069	1.069
Agst 2025	26448	28469	-2021.333	2021.333	4085785.853	-7.643	7.643
Sept 2025	26237	27863	-1625.933	1625.933	2643657.745	-6.197	6.197
Error Measurement			SDE	MAD	MSE	PE	MAPE
			2729.382	2165.408	6877973.674	-1.101	7.502

Berdasarkan Tabel 3 menunjukkan nilai hasil peramalan untuk Oktober 2025 – September 2026 sama yaitu sebesar 27375 setiap bulannya menunjukkan volume kiriman *outgoing* diproyeksikan bergerak konstan setelah periode fluktuasi pada tahun sebelumnya, sehingga dapat dijadikan acuan bagi manajemen dalam perencanaan operasional jangka menengah. Metode *Exponential Smoothing* dengan konstanta $\alpha = 0.3$ terbukti efektif dalam menggambarkan pola data historis yang berfluktuasi moderat. Meskipun hasilnya cenderung lebih *smooth* dan kurang sensitif terhadap lonjakan tajam, model ini mampu memberikan proyeksi yang stabil dan dapat diandalkan untuk mendukung perencanaan operasional dan strategi distribusi POS KCU Purwokerto. Hasil peramalan ES ditunjukkan pada Tabel 4.

Tabel 4. Hasil Peramalan Metode ES Periode Oktober 2025 – September 2026

Bulan	Forecast	Bulan	Forecast
Okt 2025	27375	Apr 2026	27375
Nov 2025	27375	Mei 2026	27375
Des 2025	27375	Juni 2026	27375
Jan 2026	27375	Juli 2026	27375
Feb 2026	27375	Agst 2026	27375
Mar 2026	27375	Sept 2026	27375



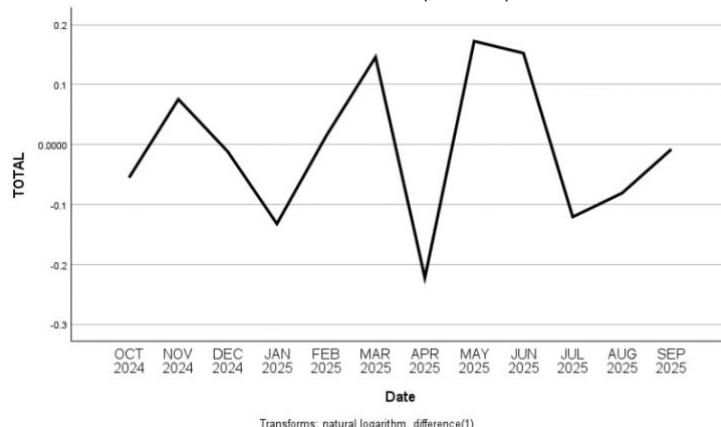
Gambar 5. Grafik Perbandingan Data Aktual dan Peramalan Metode ES

Gambar 5 menunjukkan bahwa garis hasil peramalan berwarna oranye cenderung bergerak stabil dan halus dibandingkan dengan data aktual yang menunjukkan fluktuasi cukup tajam, terutama pada periode awal hingga pertengahan tahun 2025. Metode *Exponential Smoothing* dengan konstanta $\alpha = 0.3$ efektif dalam menggambarkan kecenderungan umum dari data historis dan menghasilkan proyeksi yang stabil untuk jangka pendek hingga menengah. Namun, karena sifatnya yang lebih *smooth* dan kurang adaptif terhadap perubahan mendadak, metode ini lebih sesuai diterapkan pada pola data yang cenderung horizontal atau berfluktuasi ringan.

Metode peramalan ARIMA dilakukan menggunakan perangkat lunak SPSS, dengan

tahapan analisis yang meliputi uji stasioneritas data, estimasi model ARIMA, serta pengujian signifikansi parameter. Rangkaian langkah tersebut bertujuan untuk memperoleh model peramalan yang paling sesuai dengan karakteristik volume kiriman *outgoing*.

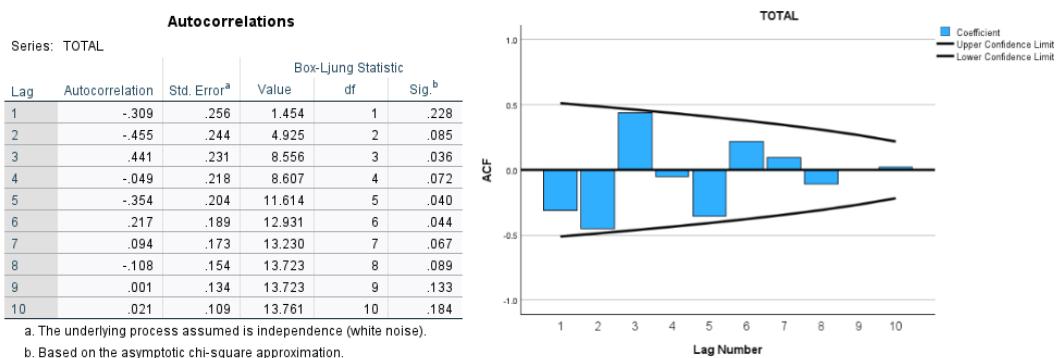
Langkah awal adalah dengan melakukan uji stasioneritas, merupakan tahap awal dalam metode ARIMA untuk memastikan bahwa data *time series* memenuhi asumsi dasar apabila memiliki varians dan nilai rata-rata yang relatif stabil sepanjang periode pengamatan. Data tidak stasioner menyebabkan estimasi parameter yang bias sehingga hasil peramalan menjadi tidak akurat. Menurut (Wei, 2006) suatu data disebut stasioner jika varians, rata-rata, dan kovariansnya tidak bergantung pada waktu observasi. Uji stasioneritas menggunakan bantuan perangkat lunak SPSS melalui tiga pendekatan, yaitu analisis *Sequence Plot*, *Autocorrelation Function* (ACF), dan *Partial Autocorrelation Function* (PACF).



Gambar 6. *Sequence Plot* Data Kiriman *outgoing* dengan $d=1$

Sequence plot digunakan untuk menggambarkan data di sekitar rata-rata tertentu dan mengidentifikasi adanya tren atau pola musiman yang mempengaruhi kestabilan data. Berdasarkan Gambar 6 dengan $d=1$ menunjukkan bahwa pola data berfluktuasi secara acak di sekitar garis nol tanpa menunjukkan adanya tren naik atau turun yang jelas. Pola tersebut memperlihatkan bahwa perubahan nilai antarperiode bersifat tidak teratur, dengan variasi amplitudo yang relatif seimbang dari waktu ke waktu. Kondisi ini menandakan bahwa rata-rata (*mean*) dan variansi data sudah stabil, yang merupakan salah satu indikasi utama bahwa data telah mencapai kondisi stasioner.

Gambar 6 menunjukkan bahwa data menjadi stasioner pada $d = 1$, sehingga parameter *differencing* pertama ($d = 1$) tepat digunakan dalam model ARIMA. Langkah ini memastikan bahwa model mampu menangkap pola acak data kiriman *outgoing* perusahaan secara lebih akurat dan stabil. Oleh sebab itu, secara visual data sudah bisa dianggap stasioner, meskipun perlu diperkuat dengan uji statistik melalui analisis ACF dan PACF.



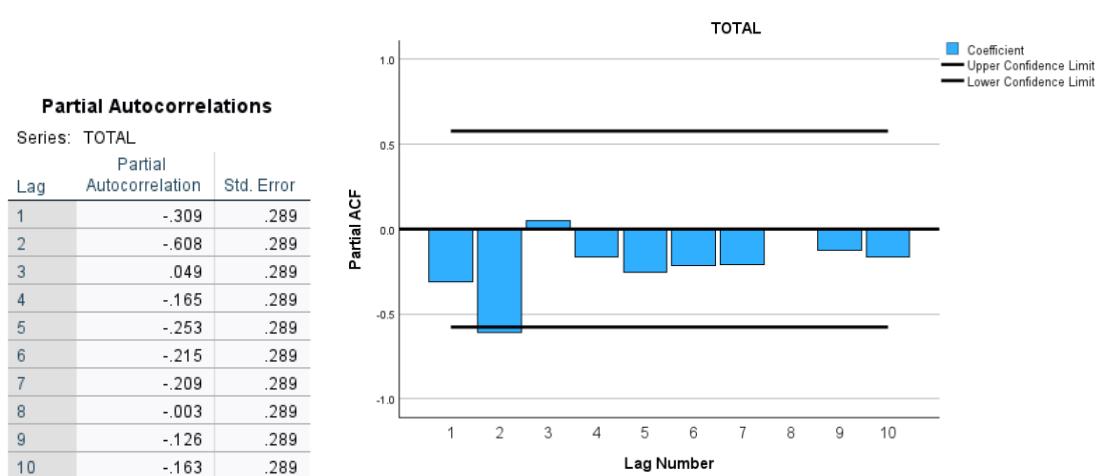
Gambar 7. Hasil Uji ACF dan Grafik ACF

Penetuan nilai ACF serta pembuatan plot dilakukan dengan SPSS. Gambar 7 menunjukkan bahwa nilai autokorelasi mengalami fluktuasi positif dan negatif pada setiap lag, yang mengindikasikan adanya pola acak (*random pattern*) setelah dilakukan proses differensiasi pertama ($d = 1$). Nilai autokorelasi yang signifikan hanya terlihat pada beberapa lag awal, yaitu lag ke-3, lag ke-5, dan lag ke-6 dengan tingkat signifikansi masing-masing sebesar 0.036, 0.040, dan 0.044 (< 0.05). Hal ini menunjukkan bahwa pada ketiga lag tersebut masih terdapat sedikit hubungan antarperiode, namun kekuatannya relatif lemah dan tidak bersifat sistematis.

Sementara itu, nilai autokorelasi pada sebagian besar lag lainnya berada di sekitar nol dengan nilai signifikansi di atas 0.05. Kondisi ini menandakan bahwa tidak terdapat hubungan serial yang berarti antarperiode waktu, sehingga pola data dapat dikatakan acak dan tidak menunjukkan adanya tren jangka panjang maupun pola musiman yang dominan. Pola seperti ini mengindikasikan bahwa data telah bersifat stasioner, karena pergerakan nilai data berfluktuasi di sekitar rata-rata tanpa menunjukkan arah peningkatan atau penurunan yang konsisten dari waktu ke waktu.

Secara keseluruhan, hasil analisis ACF ini memperkuat hasil pengamatan dari *sequence plot* yang menunjukkan bahwa data volume kiriman *outgoing* POS KCU Purwokerto telah mencapai kondisi stasioner setelah dilakukan proses differensiasi pertama. Hal ini berarti data telah memenuhi salah satu syarat utama dalam pembentukan model ARIMA. Menurut (Gujarati, D. N., & Porter, 2009) jika hasil uji Box-Ljung pada beberapa lag tidak signifikan, maka data dapat dianggap tidak memiliki autokorelasi serial, sehingga mendukung sifat stasioneritas. Dengan demikian, hasil ini memperkuat kesimpulan bahwa data kiriman *outgoing* POS KCU Purwokerto bersifat stasioner.

Pada grafik ACF, garis hitam horizontal atas dan bawah menggambarkan batas selang kepercayaan sebagai batas signifikansi autokorelasi. Suatu data dikatakan tidak stasioner apabila terdapat tiga atau lebih nilai autokorelasi pada lag awal (lag 1-3) yang melewati batas tersebut (Makridakis, S., Wheelwright, S. C., & Hyndman, 1998). Namun, pada grafik ACF terlihat bahwa seluruh batang autokorelasi masih berada dalam batas selang kepercayaan, sehingga dapat dikatakan data telah stasioner. Selain itu, pola ACF tampak menurun secara eksponensial baik pada arah positif maupun negatif, yang sesuai dengan ciri data stasioner pada proses ARIMA.

**Gambar 8. Hasil Uji PACF dan Grafik PACF**

Berdasarkan grafik hasil PACF pada Gambar 8, dapat diamati bahwa garis horizontal

bagian atas dan bawah menggambarkan batas selang kepercayaan sebagai indikator signifikansi autokorelasi parsial. Nilai autokorelasi parsial yang melewati batas tersebut menunjukkan adanya hubungan kuat antar periode pada lag tertentu. Pada grafik terlihat bahwa batang PACF signifikan hingga lag ke-2, sedangkan pada lag berikutnya nilai autokorelasi parsial menurun tajam dan berfluktuasi di sekitar nol. Pola seperti ini menunjukkan bahwa komponen *Autoregressive* (AR) yang paling mungkin terbentuk memiliki orde maksimal dua ($p \leq 2$). Selain itu, sebagian besar batang PACF setelah lag ke-2 berada dalam batas selang kepercayaan, menandakan tidak adanya autokorelasi parsial yang berkelanjutan antar periode waktu. Kondisi ini mengindikasikan bahwa data telah bersifat stasioner setelah dilakukan proses differensiasi pertama ($d = 1$), karena tidak terdapat pola sistematis yang signifikan pada laglag selanjutnya. Dengan demikian, hasil analisis PACF memperkuat kesimpulan dari uji ACF bahwa data kiriman *outgoing* POS KCU Purwokerto telah memenuhi syarat kestasioneran dan siap untuk digunakan dalam tahap identifikasi model ARIMA.

Tabel 5. Hasil Estimasi Model ARIMA

Model ARIMA	Tipe Model	Nilai p-value	RMSE	Error MAPE	MAE
(0,1,0)	Constant	0.873	3407.984	9.905	2701.347
	Constant	0.913	2712.966	7.616	2065.115
(0,1,1)	MA Lag 1	0.996			
	Constant	0.960			
	MA Lag 1	0.962	289.51	7.519	2027.975
(0,1,2)	MA Lag 2	0.940			
	Constant	0.866	3400.450	9.480	2604.797
	AR Lag 1	0.358			
(1,1,0)	Constant	0.953			
	AR Lag 1	0.893	2868.078	7.592	2058.576
	MA Lag 1	0.813			
(1,1,1)	Constant	0.998			
	AR Lag 1	0.471	2891.495	7.505	2015.01
	MA Lag 1	0.992			
(1,1,2)	MA Lag 2	0.937			
	Constant	0.824			
	AR Lag 1	0.108	2834.611	7.937	2150.354
(2,1,0)	AR Lag 2	0.062			
	Constant	0.805			
	AR Lag 1	0.991	2801.15	7.001	1867.873
(2,1,1)	AR Lag 2	0.411			
	MA Lag 1	0.919			
	Constant	0.902			
(2,1,2)	AR Lag 1	0.488			
	AR Lag 2	0.977	2909.128	7.169	1913.495
	MA Lag 1	0.977			
	MA Lag 2	0.946			

Berdasarkan hasil analisis ACF dan PACF, terlihat bahwa nilai autokorelasi menurun secara bertahap dan mulai mendekati nol setelah lag ke-2. Pola ini menunjukkan bahwa komponen AR dan MA yang berpengaruh terhadap model kemungkinan memiliki orde antara satu hingga dua. Selain itu, data telah melalui proses differensiasi pertama ($d = 1$) untuk mencapai kestasioneran. Model-model alternatif tersebut kemudian dievaluasi lebih lanjut melalui uji signifikansi parameter dan pengukuran *error measurement* untuk menentukan model

dengan kinerja terbaik. Uji signifikansi parameter dilakukan dengan menggunakan bantuan perangkat lunak SPSS.

Selanjutnya dilakukan pemilihan model ARIMA dengan membandingkan ukuran kesalahan peramalan dengan akurasi menjadi dasar utama dalam menentukan model terbaik, karena model yang memiliki nilai *error* lebih rendah dinilai mampu merepresentasikan pola data sebenarnya secara lebih akurat. Menurut (Iriawan, N., & Astuti, 2006) pengujian dapat dilakukan melalui nilai statistik *t* atau menggunakan nilai probabilitas (*p-value*). Pada pendekatan ini, parameter AR atau MA dinyatakan signifikan jika nilai *p-value* < $\alpha = 0.05$. Artinya, parameter tersebut berkontribusi secara nyata dalam model dan dapat dipertahankan. Berikut ini hasil estimasi model ARIMA berserta nilai *error*.

Tabel 5 menunjukkan nilai *p-value* > 0.05 untuk seluruh parameter AR dan MA pada model yang diuji, yang menandakan bahwa parameter tersebut tidak signifikan secara statistik. Kondisi ini dapat disebabkan oleh keterbatasan jumlah data pengamatan yang hanya mencakup 13 bulan, sehingga tidak memenuhi jumlah ideal untuk estimasi model ARIMA. Proses estimasi parameter ARIMA memerlukan sedikitnya 40-50 observasi agar hasilnya stabil dan signifikan karena jumlah data yang terbatas dapat meningkatkan nilai *standard error* sehingga menghasilkan *p-value* yang tinggi dan menurunkan kekuatan statistik (Wei, 2006). Meskipun sebagian parameter tidak signifikan, hal tersebut tidak mengindikasikan bahwa model tidak layak digunakan. Dalam analisis peramalan *time series*, pemilihan model terbaik lebih berfokus pada kemampuan model dalam menghasilkan prediksi yang akurat serta residual yang bersifat acak (*white noise*). Oleh karena itu, signifikansi parameter bukan satusatunya acuan, melainkan perlu dikombinasikan dengan evaluasi terhadap tingkat kesalahan peramalan seperti RMSE, MAE, dan MAPE (Makridakis, S., Wheelwright, S. C., & Hyndman, 1998).

Berdasarkan hasil pengujian, model ARIMA(2,1,1) menunjukkan performa terbaik dibandingkan model lainnya dengan nilai RMSE sebesar 2801.185, MAE sebesar 1867.873, dan MAPE sebesar 7.001%. Nilai kesalahan yang relatif kecil ini menunjukkan bahwa model tersebut mampu merepresentasikan pola data kiriman *outgoing* dengan baik. Oleh karena itu, meskipun sebagian besar parameter dalam model ARIMA(2,1,1) tidak signifikan secara statistik, model ini tetap dinilai paling layak digunakan. Model tersebut terbukti memberikan hasil peramalan dengan tingkat kesalahan terkecil dan pola residual yang mendekati *white noise*, sehingga dapat dijadikan dasar dalam perencanaan estimasi volume kiriman *outgoing*. Berikut hasil peramalan menggunakan metode ARIMA yang menunjukkan bahwa metode cukup stabil dalam mengikuti pola historis data.

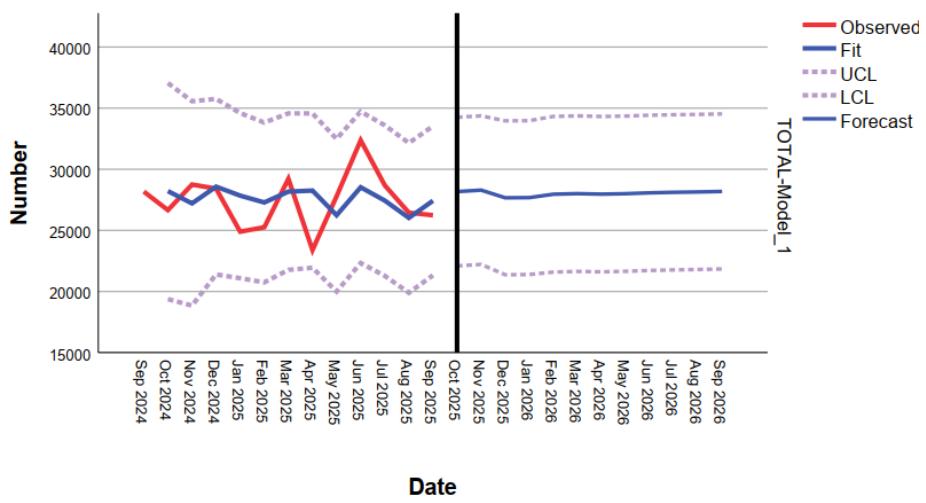
Tabel 6. Hasil Peramalan Metode ARIMA

Bulan	Forecast	Bulan	Forecast
Okt 2025	28171	Apr 2026	27963
Nov 2025	28292	Mei 2026	28002
Des 2025	27665	Juni 2026	28072
Jan 2026	27680	Juli 2026	28113
Feb 2026	27957	Agst 2026	28144
Mar 2026	28006	Sept 2026	28184

Fit Statistic	Mean	SE	Minimum	Maximum	Percentile	
					5	10
Stationary	.509	.	.509	.509	.509	.509
R-squared	.008	.	-.008	-.008	-.006	-.006
RMSE	2801.185	.	2801.185	2801.185	2801.185	2801.185
MAPE	7.001	.	7.001	7.001	7.001	7.001
MaxAPE	20.811	.	20.811	20.811	20.811	20.811
MAE	1867.873	.	1867.873	1867.873	1867.873	1867.873
MaxAE	4867.595	.	4867.595	4867.595	4867.595	4867.595
Normalized	16.704	.	16.704	16.704	16.704	16.704
BIC						

Gambar 9. Output Model Fit

Tabel Model Fit menunjukkan bahwa model ARIMA (2,1,1) memiliki tingkat kesalahan peramalan tergolong rendah sehingga model dapat dikatakan cukup akurat dalam memprediksi data aktual. Nilai *Stationary R-squared* sebesar 0.509 menunjukkan bahwa sekitar 50.9% variasi data stasioner dapat dijelaskan oleh model, sedangkan *R-squared* bernilai -0,006 mengindikasikan bahwa kemampuan model dalam menjelaskan variasi data aktual masih terbatas, kemungkinan disebabkan oleh adanya fluktuasi permintaan. Hal ini cukup memadai untuk konteks data operasional yang dipengaruhi lonjakan permintaan secara mendadak.



Gambar 10. Grafik Perbandingan Data Aktual dan Peramalan Metode ARIMA

Gambar 10 menunjukkan bahwa garis merah merepresentasikan data aktual (*observed*), sedangkan garis biru menunjukkan hasil proyeksi model ARIMA (*fit*). Area di sisi kanan garis vertikal hitam merupakan hasil peramalan (*forecast*) untuk periode Oktober 2025 hingga September 2026. Sementara itu, garis ungu atas (UCL) dan bawah (LCL) menggambarkan batas selang kepercayaan sebesar 95%, yang menunjukkan rentang kemungkinan variasi nilai peramalan. Pola garis hasil estimasi model ARIMA ditunjukkan mampu mengikuti arah pergerakan data aktual dengan cukup baik, terutama pada periode dengan fluktuasi. Dengan demikian, model ini dapat dinilai layak untuk digunakan dalam memperkirakan volume pengiriman di masa mendatang.

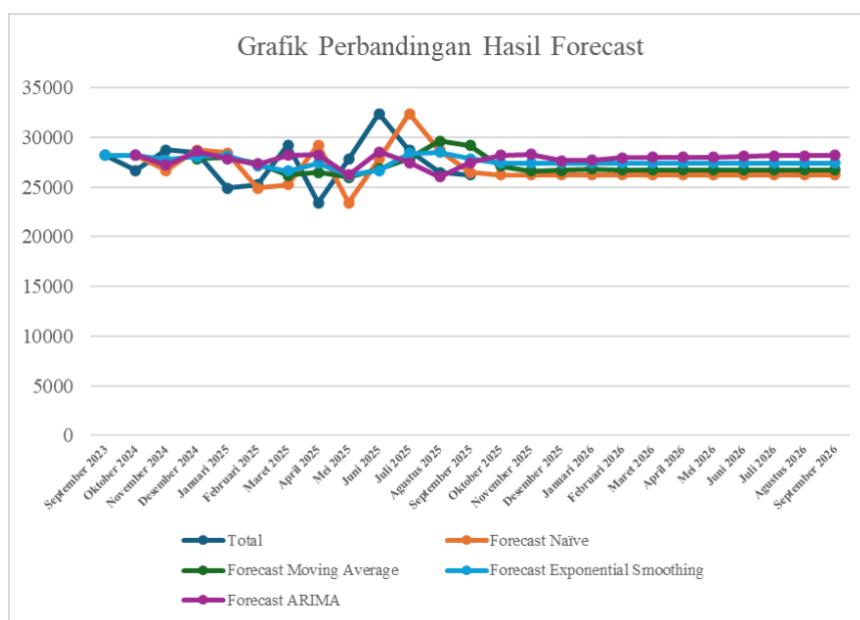
Tabel 7 menunjukkan ARIMA lebih konsisten dalam meminimalkan rata-rata deviasi

absolut dan kesalahan persentase terhadap data aktual, memberikan keseimbangan antara tingkat kesalahan yang rendah dan kestabilan hasil peramalan. Selain itu, nilai MAPE berada di bawah 10% masuk dalam kategori *highly accurate forecasting* (Lewis, 1982), sehingga dapat dikatakan metode ARIMA dinilai memiliki tingkat ketepatan prediksi yang sangat baik.

Tabel 7. Perbandingan Akurasi Peramalan

Metode	MAD	MSE	MAPE
Naïve	2728,25	10672547,583	10,027%
Moving Average	2613,967	8631361,767	9,587%
Exponential Smoothing	2165,408	6877973,674	7,502%
ARIMA	1867,873	7846634,404	7,001%

Berdasarkan Gambar 11 terlihat bahwa seluruh metode peramalan mengikuti pola fluktuasi data aktual (Total), namun dengan tingkat variasi yang berbeda. Garis *forecast* ARIMA tampak paling mendekati nilai aktual (Total), menunjukkan bahwa metode ini mampu merepresentasikan pola historis dengan baik sekaligus memberikan proyeksi yang konsisten di masa mendatang sehingga metode ARIMA (2,1,1) dinyatakan sebagai metode paling tepat dalam memproyeksikan volume kiriman *outgoing* di POS KCU Purwokerto. Model ini menghasilkan estimasi yang lebih akurat dibandingkan metode lainnya dan dapat dijadikan dasar bagi perusahaan dalam menyusun strategi pengelolaan kiriman. Strategi berbasis hasil peramalan ini diharapkan mampu membantu perusahaan tetap optimal dalam menghadapi fluktuasi maupun lonjakan volume pengiriman pada periode tertentu tanpa mengganggu kelancaran operasional, serta mendukung efisiensi dan keberlanjutan layanan logistik di masa mendatang.



Gambar 11. Grafik Perbandingan Hasil Peramalan

Hasil peramalan memberikan gambaran yang akurat mengenai pola fluktuasi permintaan yang dapat dimanfaatkan sebagai dasar dalam pengambilan keputusan manajerial terutama terkait pengaturan kapasitas armada, penjadwalan distribusi, dan alokasi karyawan sehingga dapat meminimalkan potensi keterlambatan pengiriman akibat ketidakseimbangan antara kapasitas dan beban kerja. Dengan proyeksi yang lebih tepat, perusahaan dapat

merencanakan strategi operasional yang lebih adaptif terhadap dinamika permintaan, menjaga kelancaran distribusi, serta meningkatkan efisiensi dan keberlanjutan layanan logistik di masa mendatang

KESIMPULAN

Berdasarkan penelitian yang dilakukan, permasalahan keterlambatan kiriman *outgoing* pada POS KCU Purwokerto karena kurangnya antisipasi dari perusahaan dapat diselesaikan dengan menggunakan metode peramalan yang tepat agar perusahaan dapat memperkirakan sumber daya dan strategi yang dibutuhkan agar keterlambatan dalam proses distribusi dapat dikurangi. Data historis volume kiriman *outgoing* POS KCU Purwokerto pada periode September 2024 sampai September 2025 menunjukkan pola horizontal. Volume bergerak stabil di kisaran 24.000- 33.000 per bulan, dengan sedikit lonjakan pada Juni 2025. Pola ini sesuai dengan karakteristik *time series* jangka pendek sehingga metode peramalan yang relevan adalah *Naïve*, *Moving Average*, *Exponential Smoothing*, dan ARIMA (*Autoregressive Integrated Moving Average*).

Metode ARIMA (*Autoregressive Integrated Moving Average*) dengan model (2,1,1) terpilih sebagai model terbaik dengan tingkat kesalahan terkecil, yakni MAD sebesar 1867.87, MSE sebesar 7846634.40, dan MAPE sebesar 7.001%. Hasil peramalan (*forecast*) volume kiriman *outgoing* selama satu tahun dari Oktober 2025 hingga September 2026 ditunjukkan oleh Tabel 6 dengan rata-rata 27975. Penelitian selanjutnya dapat menambah kembali data historis sehingga pola yang akurat dapat terlihat dan menggunakan metode peramalan lainnya atau bahkan dapat menggunakan machine learning untuk memprediksi permintaan barang kiriman *outgoing*.

REFERENSI

- Barry Render, J. H. (2001). *Prinsip-Prinsip Manajemen Operasi*. Salemba Empat.
- Christopher, M. (2016). *Logistics & Supply Chain Management* (5th ed.). Pearson Education Limited.
- Dadang Surya Kencana, Sipon Al Munir, Y. P. M. (2025). Pengaruh Sistem Pelacakan Online dan Ketepatan Waktu Pengiriman terhadap Kepuasan Pelanggan. *JURNAL LENTERA BISNIS*, 14(2), 2926-2939. <https://doi.org/10.34127/jrlab.v14i2.1760>
- Gujarati, D. N., & Porter, D. C. (2009). *Basic Econometrics* (5th ed.). McGraw-Hill, Inc.
- Herjanto, E. (2007). *Manajemen Operasi* (Edisi 3). Grasindo.
- Iriawan, N., & Astuti, S. P. (2006). *Mengolah Data Statistik dengan Mudah Menggunakan Minitab*. Andi Offset.
- Jacobs, F. R., & Chase, R. B. (2016). *Operations and Supply Chain Management* (14th ed.). McGraw-Hill Education.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and Applications* (3rd ed.). John Wiley & Sons.
- Maqbulla Arochman, M. T. (2021). Pengaruh Kualitas Layanan terhadap Keinginan Berpindah Pengguna Jasa Layanan Rumah Kos di Jatimulyo Malang dengan Kepuasan Pelanggan sebagai Variabel Mediating. *Jurnal GeoEkonomi ISSN-Elektronik*, 12(1), 17-24. <https://doi.org/doi.org/10.36277/geoekonomi>
- Mulyono, S. (2000). *Peramalan Bisnis*. Liberty.
- Nachrowi, N. D., & Usman, H. (2004). *Pendekatan Populer dan Praktis Ekonometrika untuk Analisis Ekonomi dan Keuangan*. embaga Penerbit Fakultas Ekonomi Universitas Indonesia.
- Nasapi, A., Surarso, B., & Cahyo, B. N. (2014). Analisis Peramalan Permintaan untuk Mengurangi Risiko Ketidaktepatan Inventory pada Perusahaan Distribusi. *Jurnal Teknik Industri*, 15(2), 101-110.
- Nasution, M. N., & Prasetyawan, Y. (2008). *Manajemen Transportasi*. Ghalia Indonesia.
- Nevi Fitria Aini, Deden Darmansyah, Rahmad Apriyono, Ramdhani, Y., & Prastyo. (2025). Literature Review: Faktor-Faktor yang Mempengaruhi Kepuasan Pelanggan dalam Layanan Pengiriman Barang. *Journal of Management and Innovation Entrepreneurship (JMIE)*, 2(4), 2305-2314.
- Octora, R., & Kuntoro, H. (2013). *Peramalan Deret Waktu dengan Model ARIMA*. Penerbit Andi Offset.
- Rahmayani, R., Handayani, S., Telaumbanua, A., Fitrah, A., & Rayhan, M. (2025). Peramalan terhadap

- permintaan pengiriman barang di PT. Khan Trans Indonesia menggunakan metode Moving Average & Exponential Smoothing periode Januari 2025. *NNOVATIVE: Journal of Social Science Research*, 5(1), 5295–5310.
- Ritzman, L. P., Krajewski, L. J., & Malhotra, M. K. (2013). *Foundations of Operations Management* (8th ed.). Pearson Education.
- Rushton, A., Croucher, P., & Baker, P. (2017). *The Handbook of Logistics and Distribution Management* (6th ed.). Kogan Page.
- Sinulingga, S. (2013). *Metode Penelitian untuk Teknik Industri*. Graha ilmu.
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate Methods* (2nd ed.). Pearson Addison Wesley.