

Implementasi Model ARIMA untuk Peramalan Reorder Point dalam Supply Chain Management

Andrea Cellista Alexandra*, Kristoko Dwi Hartomo

Fakultas Teknologi Informasi, Sistem Informasi, Universitas Kristen Satya Wacana, Salatiga, Indonesia

Email: ¹*682021034@student.uksw.edu, ²kristoko@uksw.edu

Email Penulis Korespondensi: 682021034@student.uksw.edu

Submitted 22-05-2025; Accepted 30-06-2025; Published 30-06-2025

Abstrak

Penelitian ini menganalisis pola dan tren reorder point dalam pengelolaan persediaan selama dua tahun (2023-2024) menggunakan data deret waktu mingguan hasil *resampling* data harian. Metode ARIMA (Autoregressive Integrated Moving Average) diterapkan untuk memprediksi nilai reorder point. Hasil uji stasioneritas Augmented Dickey-Fuller (ADF) menunjukkan bahwa data awal tidak stasioner, tetapi menjadi stasioner setelah dilakukan *differencing* satu kali. Identifikasi parameter model melalui grafik Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) mengarah pada pemilihan model ARIMA(1,1,1) sebagai yang terbaik, berdasarkan nilai Akaike Information Criterion (AIC) terendah. Evaluasi akurasi model menggunakan Mean Absolute Percentage Error (MAPE) menghasilkan nilai 0,02%, yang mengindikasikan tingkat akurasi prediksi yang sangat baik. Dengan demikian, model ARIMA terbukti andal dalam memprediksi reorder point, mendukung pengambilan keputusan yang lebih tepat dalam manajemen persediaan.

Kata kunci: Reorder Point; ARIMA; Deret Waktu; Stasioneritas; MAPE; Prediksi Persediaan.

Abstract

This research analyzes the patterns and trends of reorder points in inventory management over a two-year period (2023-2024), utilizing weekly time series data generated from daily data resampling. The ARIMA (Autoregressive Integrated Moving Average) method was applied to forecast future reorder point values. An Augmented Dickey-Fuller (ADF) stationarity test revealed that the initial data was non-stationary but became stationary after a single differencing operation. Parameter identification using Autocorrelation Function (ACF) and Partial Autocorrelation Function (PACF) plots indicated that the ARIMA(1,1,1) model was the best choice, based on the lowest Akaike Information Criterion (AIC). Model accuracy was evaluated using Mean Absolute Percentage Error (MAPE), yielding a value of 0.02%, signifying an excellent level of prediction accuracy. Consequently, the ARIMA model is demonstrated to be reliable for forecasting reorder points, supporting more precise decision-making in inventory management.

Keywords: Reorder Point; ARIMA; Time Series; Stationarity; MAPE; Inventory Prediction

1. PENDAHULUAN

Manajemen persediaan memainkan peran penting dalam menjaga aliran barang yang lancar dari pemasok ke produsen hingga ke konsumen dalam pengelolaan rantai pasok (SCM). Salah satu masalah utama dalam manajemen persediaan adalah menentukan kapan dan berapa banyak stok yang harus dipesan kembali untuk mencegah *stock-out* atau *overstock*. *Reorder Point (ROP)*, atau titik pemesanan ulang, adalah komponen penting dalam manajemen persediaan. Jika penentuan *ROP* yang salah dilakukan, hal itu dapat menyebabkan proses produksi yang tertunda, biaya penyimpanan yang lebih tinggi, atau bahkan hilangnya peluang penjualan karena produk yang tidak tersedia pada saat yang dibutuhkan [1].

PT XYZ menghadapi masalah dengan metode konvensional berbasis spreadsheet dalam peramalan kebutuhan stok dan penentuan *Reorder Point (ROP)*. Metode ini sangat rentan terhadap kesalahan manusia, tidak responsif terhadap perubahan pola permintaan, dan tidak dapat menangkap tren dan fluktuasi musiman dengan tepat. PT XYZ kesulitan mempertahankan efisiensi operasional dan daya saing dalam kondisi pasar yang semakin kompetitif dan dinamis. Oleh karena itu, perlu diterapkan suatu strategi berbasis teknologi yang dapat membantu bisnis dalam meningkatkan akurasi peramalan permintaan dan menemukan *Reorder Point* dengan cara yang paling efektif. Metode *Autoregressive Integrated Moving Average (ARIMA)* adalah salah satu solusi yang dapat digunakan. *ARIMA* adalah salah satu teknik peramalan deret waktu yang memiliki kemampuan untuk menganalisis tren, fluktuasi, dan musiman dalam data historis. Dengan pendekatan *ARIMA*, perusahaan dapat memproyeksikan kebutuhan masa depan dengan lebih akurat sehingga pengadaan stok dapat dilakukan tepat waktu dan dalam jumlah yang sesuai [2]. Selain itu, untuk mengukur keakuratan hasil peramalan, digunakan indikator *Mean Absolute Percentage Error (MAPE)*, yang menunjukkan seberapa besar kesalahan relatif antara nilai aktual dan nilai hasil peramalan. Nilai *MAPE* yang rendah menunjukkan bahwa model peramalan memiliki tingkat akurasi yang tinggi [3].

Berbagai penelitian sebelumnya telah menunjukkan efektivitas metode *ARIMA* dalam melakukan peramalan. Penelitian oleh Gubu et al. (2024) menerapkan model *ARIMA* (1,1,0) untuk meramalkan harga penutupan saham PT Bank Central Asia Tbk selama bulan Januari 2023. Dalam penelitian ini, model *ARIMA* yang digunakan berhasil mengidentifikasi pola-pola yang ada dalam data historis harga saham tersebut. Hasil penelitian menunjukkan bahwa model tersebut berhasil menghasilkan *MAPE* sebesar 1,07%, yang menunjukkan tingkat akurasi yang tinggi. *MAPE* yang rendah ini mengindikasikan bahwa model *ARIMA* (1,1,0) dapat digunakan dengan baik untuk meramalkan harga saham dalam jangka pendek. Oleh karena itu, penelitian ini membuktikan bahwa metode *ARIMA* dapat memberikan prediksi yang cukup akurat dalam pasar saham yang dinamis [4].

Sementara itu, penelitian oleh Qodri et al. (2024) menggunakan *ARIMA* (0,1,1) dengan intervensi fungsi *step* dan *pulse* untuk meramalkan harga saham PT Kimia Farma Tbk. Penelitian ini lebih fokus pada perbaikan akurasi model *ARIMA* dengan mengintegrasikan fungsi *step* dan *pulse*, yang merupakan jenis intervensi dalam analisis deret waktu untuk menangani perubahan mendadak dalam pola data. Hasil penelitian menunjukkan bahwa intervensi pada model *ARIMA* dapat meningkatkan akurasi peramalan, dengan nilai *MAPE* sebesar 0,3356%. Hal ini menunjukkan bahwa dengan menambahkan intervensi, model *ARIMA* dapat lebih responsif terhadap fluktuasi yang tidak terduga dalam data, sehingga memberikan hasil yang lebih optimal dalam meramalkan harga saham [5].

Penelitian lain yang dilakukan oleh Maya Sari Wahyuni, Ahmad Zaki, Syarif Hidayat, dan Muhammad Isbar Pratama pada tahun (2024) mengkaji peramalan kebutuhan energi listrik di Kota Makassar. Data konsumsi bulanan selama periode 2018–2022 menunjukkan fluktuasi, sehingga diperlukan model peramalan untuk mendukung perencanaan energi. Tujuan penelitian ini adalah menentukan model *Autoregressive Integrated Moving Average* (*ARIMA*) terbaik untuk meramalkan kebutuhan energi 12 bulan ke depan. Tahapan analisis meliputi identifikasi kestasioneran, estimasi parameter, uji asumsi residual, dan evaluasi akurasi menggunakan *Mean Absolute Percentage Error* (*MAPE*). Hasil menunjukkan bahwa model *ARIMA*(1,0,0) dengan *MAPE* sebesar 0,4735% memiliki akurasi sangat baik dan layak digunakan dalam peramalan kebutuhan energi listrik. mengkaji Konsumsi energi listrik di Kota Makassar pada periode 2018–2022 mengalami fluktuasi bulanan, sehingga diperlukan peramalan untuk mendukung perencanaan kebutuhan energi. Penelitian ini bertujuan menentukan model *Autoregressive Integrated Moving Average* (*ARIMA*) terbaik untuk meramalkan kebutuhan energi listrik 12 bulan ke depan. Proses analisis meliputi identifikasi kestasioneran, estimasi parameter, uji asumsi residual, dan evaluasi akurasi menggunakan *Mean Absolute Percentage Error* (*MAPE*). Hasil menunjukkan bahwa model *ARIMA*(1,0,0) dengan nilai *MAPE* sebesar 0,4735% memberikan akurasi sangat baik dan layak digunakan dalam peramalan energi listrik [6].

Selanjutnya, Penelitian dilakukan oleh Lia Aulia Hayati dan Neli Agustina (2024) dari Politeknik Statistika STIS membahas peramalan Produk Domestik Regional Bruto (PDRB) sektor pertambangan dan penggalian di Kalimantan Selatan. Sektor ini merupakan salah satu sektor unggulan, namun memiliki tantangan berupa keterbatasan sumber daya. Dalam rangka mendukung target pertumbuhan ekonomi nasional sebagaimana tercantum dalam RPJMN 2020–2024, penelitian ini menggunakan model *Autoregressive Integrated Moving Average* (*ARIMA*) untuk meramalkan nilai PDRB sektor tersebut. Hasil analisis menunjukkan bahwa model terbaik adalah *ARIMA*(2,1,4) dengan tingkat akurasi *Mean Absolute Percentage Error* (*MAPE*) sebesar 5,054%. Peramalan menunjukkan tren peningkatan nilai PDRB di tahun 2024, yang diharapkan dapat menjadi dasar bagi pengambilan kebijakan strategis dalam menjaga keberlanjutan sektor pertambangan dan penggalian, yang juga merupakan sektor dengan tingkat penyerapan tenaga kerja yang tinggi [7].

Berdasarkan latar belakang yang telah diuraikan, tujuan dari penelitian ini adalah untuk memberikan kontribusi nyata dalam meningkatkan efisiensi manajemen persediaan, mengurangi risiko *stock-out* maupun *overstock*, serta menjadi dasar pengambilan keputusan yang lebih akurat dan berbasis data dalam sistem rantai pasok Perusahaan dengan mengimplementasikan metode *Autoregressive Integrated Moving Average* (*ARIMA*) dalam peramalan kebutuhan persediaan di PT XYZ. Selain itu, metode *ARIMA* akan dipadukan dengan pengujian *white noise* guna memastikan bahwa *residual* (sisa peramalan) dari model bersifat acak, tidak berkorelasi, dan memiliki varians konstan. Hal ini penting untuk menjamin bahwa model *ARIMA* telah berhasil menangkap seluruh pola dalam data historis dan tidak meninggalkan struktur yang dapat diprediksi. Pengujian ini dilakukan menggunakan statistik uji *Ljung-Box*, yang merupakan metode standar dalam evaluasi model deret waktu [8].

2. METODOLOGI PENELITIAN

2.1 Business Understanding

Menurut penelitian yang dilakukan oleh Rizki Kurniawan F, Sutomo R, tahap ini bertujuan untuk memahami kebutuhan analisis dalam konteks dunia nyata, yaitu untuk melakukan *forecasting* terhadap ketersediaan suatu komoditas agar dapat membantu perencanaan di masa mendatang. Tujuan dari proses ini adalah untuk melihat pola dan tren yang ada sehingga bisa digunakan dalam proses pengambilan keputusan [9].

2.2 Data Understanding

Pada tahap ini, dilakukan identifikasi awal terhadap struktur data yang akan dianalisis. Penelitian ini menjelaskan bahwa data yang digunakan terdiri dari dua komponen utama, yaitu:

- Waktu (dalam format bulanan-tahunan)
- Nilai produksi (dalam bentuk angka)

Data understanding mencakup proses peninjauan apakah data memiliki pola, tren musiman, atau *outlier*, serta melihat apakah data tersebut cukup representatif untuk digunakan dalam *forecasting* [9].

2.3 Data Preparation

Sebelum proses *forecasting* dilakukan, data perlu disiapkan dengan beberapa langkah, antara lain:

- Menyesuaikan *time index* agar data dapat dibaca sebagai *time series*.
- Membersihkan nilai yang hilang, agar hasil analisis tidak *bias*.
- Mengatur format numerik dari variabel yang akan diprediksi.

- d. Membagi data secara sistematis untuk keperluan validasi model dan pengujian hasil prediksi.
Tahapan ini memastikan bahwa data sudah dalam kondisi optimal untuk dianalisis.

2.4 Modeling

Tahap modeling bertujuan membangun model *ARIMA* dengan memastikan data bersifat stasioner. Jika tidak, dilakukan pembedaan (*differencing*) untuk menentukan nilai d menggunakan *ACF* atau uji *unit root*. Jika data sudah stasioner, maka $d = 0$. Selanjutnya, ditentukan nilai p dan q dengan menganalisis pola grafik *ACF* dan *PACF*. *PACF* menunjukkan hubungan antar lag dengan mengontrol pengaruh lag lainnya. Hasil dari analisis ini digunakan untuk menentukan bentuk model *ARIMA*(p,d,q) yang sesuai dengan data [10].

2.5 Model Evaluation

Tahap ini dilakukan untuk mengevaluasi apakah parameter-parameter dalam model hasil estimasi memiliki pengaruh yang signifikan secara statistik. Evaluasi ini biasanya dilakukan melalui *significance testing* dengan mengamati nilai *p-value* dari setiap koefisien. Jika *p-value* lebih kecil dari tingkat signifikansi tertentu (misalnya 0,05), maka parameter tersebut dianggap signifikan dan dapat dipertahankan dalam model [11].


Selain itu, dilakukan juga pengujian terhadap *residual model* untuk memastikan bahwa model *ARIMA* yang dibangun sudah cukup baik dalam menangkap pola data. Salah satu pengujian penting dalam tahap ini adalah uji *white noise* terhadap *residual*. *Residual* dikatakan memenuhi asumsi *white noise* jika bersifat acak, tidak menunjukkan *autokorelasi*, memiliki rata-rata nol, dan *varians* konstan [8].

2.6 Deployment

Tahapan akhir dari proses ini adalah penerapan model untuk kebutuhan praktis, yaitu melakukan prediksi terhadap nilai di masa mendatang. Penelitian ini menjelaskan bahwa model yang sudah tervalidasi digunakan untuk melihat kemungkinan hasil produksi ke depan, sehingga hasil prediksi dapat dimanfaatkan dalam perencanaan yang lebih terarah dan akurat [9].

2.7 Tahapan Penelitian

Penelitian ini memiliki tahapan-tahapan yang dapat dilihat pada Gambar 1 sebagai berikut. Pertama, data dikumpulkan dan melalui proses *cleaning* secara sistematis guna memastikan kualitas dan integritas data sebagai dasar yang kuat dalam pengembangan model peramalan yang valid. Kedua, dilakukan uji *stationarity* untuk menentukan apakah data bersifat stasioner. Ketiga, jika data tidak stasioner, maka dilakukan transformasi atau *differencing* hingga data menjadi stasioner. Keempat, setelah data dinyatakan stasioner, dilakukan identifikasi parameter *ARIMA* yaitu nilai p , d , dan q . Dalam tahap ini, model *ARIMA* diuji dengan berbagai kombinasi parameter dan masing-masing dievaluasi menggunakan nilai *AIC* (*Akaike Information Criterion*). Nilai *AIC* yang lebih kecil menunjukkan model yang lebih baik dalam hal keseimbangan antara kompleksitas dan kecocokan terhadap data. Oleh karena itu, model dengan *AIC* terkecil dipilih untuk dianalisis lebih lanjut [12]. Kelima, model *ARIMA* dibangun berdasarkan parameter terbaik yang telah ditentukan. Keenam, dilakukan pengujian *white noise* terhadap *residual* model untuk memastikan bahwa sisa kesalahan model bersifat acak. *Residual* yang acak menunjukkan bahwa model sudah cukup baik dalam menangkap pola dalam data. Namun, jika *residual* tidak bersifat acak, maka model dianggap belum optimal dan perlu dilakukan perbaikan dengan kembali ke tahap identifikasi parameter. Ketujuh, jika *residual* telah memenuhi asumsi *white noise*, maka dilakukan uji signifikansi terhadap parameter model untuk memastikan bahwa parameter yang digunakan memiliki pengaruh yang nyata secara statistik. Jika hasil uji menunjukkan parameter tidak signifikan, maka model perlu diperbaiki. Sebaliknya, jika signifikan, maka proses dilanjutkan ke tahap evaluasi model. Kedelapan, evaluasi dilakukan dengan menghitung nilai *MAPE* (*Mean Absolute Percentage Error*). Jika nilai *MAPE* lebih dari 20%, maka model dianggap kurang akurat dan perlu diperbaiki. Kesembilan, jika nilai *MAPE* kurang dari atau sama dengan 20%, maka model dinyatakan akurat dan dapat digunakan untuk melakukan *forecasting* atau prediksi.



Gambar 1. Langkah-langkah Penelitian

- Langkah yang dilakukan dalam penelitian ini antara lain:
- Pertama, proses pembuatan model *Autoregressive Integrated Moving Average (ARIMA)* dimulai dengan pengumpulan data historis dari file CSV berisi data *time series* perpindahan barang, dilanjutkan dengan tahap *data cleaning* untuk memastikan kualitas dan konsistensi data sebelum dianalisis lebih lanjut.
 - Kedua, dilakukan uji *stationarity* secara visual dan statistik menggunakan *ADF Test* untuk memastikan bahwa *mean* dan *variance* data stabil sepanjang waktu.

Rumus ADF Test:

$$\Delta y_t = \alpha + \beta t + \gamma y_t - 1 + \sum i = 1 p \delta i \Delta y_t - i + \epsilon_t \quad (1)$$

di mana:

y_t : nilai *time series* pada waktu ke- t

Δy_t : perubahan nilai data (*first difference*) pada waktu ke- t

γ : koefisien yang menunjukkan tingkat *stationarity*

ϵ_t : *error term* atau gangguan acak pada waktu ke- t

Hipotesis uji ADF:

H_0 : Data tidak stasioner (jika $p\text{-value} > 0.05$)

- H₁ : Data *stasioner* (jika $p\text{-value} \leq 0.05$) [13]
- Ketiga, jika data sudah *stationary*, proses dilanjutkan ke identifikasi parameter. Jika belum, dilakukan transformasi seperti *differencing* atau *log transform* hingga data menjadi *stationary*, lalu diuji kembali [14].
 - Keempat, setelah data *stationary*, ditentukan parameter model *ARIMA*, yaitu p (*autoregressive*), d (*differencing*), dan q (*moving average*), dengan bantuan grafik *ACF* dan *PACF*.
 p (*autoregressive order*): diambil dari *PACF* cut-off. Jika *PACF* turun drastis ke nol setelah lag tertentu, nilai p diambil pada lag tersebut.
 d (*differencing order*): jumlah *differencing* yang dibutuhkan agar data menjadi *stationary*. Umumnya, $d \leq 2$.
 q (*moving average order*): diambil dari *ACF* cut-off. Jika *ACF* turun drastis ke nol, nilai q diambil pada lag terakhir sebelum cut-off. [15]
 - Kelima, dengan parameter yang telah ditentukan, model *Autoregressive Integrated Moving Average (ARIMA)* dibangun menggunakan rumus:

$$Y_t' = c + \sum_{i=1}^p \theta_i Y_{t-i}' - i + \sum_{j=1}^q \theta_j \epsilon_{t-j} - j + \epsilon_t \quad (2)$$

di mana:

c = konstanta

ϕ_i = koefisien *autoregressive (AR)*

θ_j = koefisien *moving average (MA)*

ϵ_t = *error term* atau kesalahan acak pada waktu ke- t [14]

- Keenam, Setelah model *ARIMA* dibangun, langkah selanjutnya adalah melakukan *uji white noise* pada residual, yaitu menguji apakah sisa kesalahan (residual) dari model bersifat acak atau tidak. Jika residual bersifat acak (*white noise*), maka model dianggap sudah sesuai karena telah berhasil menangkap seluruh pola dalam data, sehingga model dapat digunakan untuk prediksi. Namun, jika residual tidak bersifat acak, maka hal ini menunjukkan bahwa masih terdapat pola dalam data yang belum terakomodasi oleh model. Dalam kasus ini, model perlu diperbaiki dengan kembali melakukan transformasi data atau mengidentifikasi ulang parameter *ARIMA*.
 Dalam konteks umum, *AIC* dihitung dengan rumus:

$$AIC = n \ln \left(\hat{\sigma}^2 \right) + 2(p + q + 1) \quad (3)$$

Dengan $\hat{\sigma}^2 = \frac{SSE}{N}$, *SSE* adalah nilai jumlahan residual kuadrat, serta p dan q adalah orde dari model *ARIMA*. [8].

- Ketujuh, Setelah melakukan tahapan *uji white noise*, selanjutnya dilakukan estimasi parameter untuk mendapatkan nilai koefisien. Setiap koefisien (seperti *AR* dan *MA*) diuji dengan $p\text{-value}$. Jika $p\text{-value} < 0,05$, koefisien dianggap signifikan, yang berarti kontribusinya cukup kuat secara statistik. Sebaliknya, koefisien dengan $p\text{-value} \geq 0,05$ dianggap tidak signifikan, dan model dapat diperbaiki atau disesuaikan. Pemeriksaan signifikansi parameter penting untuk memastikan bahwa struktur model merepresentasikan pola data dengan baik untuk proses *forecasting* yang andal [16].
- Kedelapan, lakukan evaluasi akurasi model menggunakan nilai *Mean Absolute Percentage Error (MAPE)*. Jika *Mean Absolute Percentage Error (MAPE)* $> 20\%$, maka model dianggap kurang akurat dan perlu dilakukan pemodelan ulang. Sebaliknya, jika *Mean Absolute Percentage Error (MAPE)* $\leq 20\%$, maka model dianggap cukup akurat dan proses dapat dilanjutkan.

Berikut adalah rumus *MAPE* yang diterapkan:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (4)$$

Di mana:

n = jumlah periode pengamatan

A_t = nilai aktual pada periode ke- t

F_t = nilai peramalan pada periode ke- t [17]

Kategori *MAPE* yang diterapkan dalam Interpretasi *MAPE* dapat dilihat pada Tabel 1

Tabel 1. Kategori Peramalan *MAPE*

MAPE (%)	Interpretasi MAPE
$x < 10\%$	Peramalan sangat akurat
$10\% \leq x < 20\%$	Peramalan tersebut baik
$20\% \leq x < 50\%$	Peramalan masih dalam kewajaran
$x \geq 50\%$	Peramalan tidak akurat

- Kesembilan, Peramalan, juga disebut *forecasting*, adalah upaya untuk menggunakan data dan informasi saat ini untuk memperkirakan apa yang mungkin terjadi di masa depan. Tujuannya adalah untuk mengetahui kapan suatu peristiwa terjadi sehingga tindakan yang tepat dapat diambil untuk membantu proses pengambilan Keputusan [18]. Terakhir, prediksi dilakukan dengan memilih model yang menghasilkan nilai *Mean Absolute Percentage Error (MAPE)* terkecil. Ini karena *MAPE* digunakan sebagai metrik untuk mengukur akurasi prediksi dibandingkan dengan

nilai aktual, dan nilai *MAPE* yang lebih kecil menunjukkan kemampuan model untuk memprediksi nilai yang sebenarnya [19]

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Pada tahap pertama, data yang dikumpulkan mencakup informasi mengenai reorder point yang terjadi selama dua tahun penuh pada tahun 2023 dan 2024. Data ini diperoleh dari sistem manajemen persediaan yang ada, dengan rincian yang sangat terperinci, yaitu berdasarkan minggu (*per-week*). Tujuan utama pengumpulan data ini adalah untuk memperoleh gambaran yang lebih terstruktur mengenai tren dan pola *reorder point* sepanjang minggu, yang memungkinkan untuk melakukan analisis lebih mendalam terhadap fluktuasi dan pola permintaan yang mungkin ada pada periode tersebut. Data yang dikumpulkan ini juga mencakup faktor-faktor terkait yang dapat mempengaruhi reorder point, seperti lead time, fluktuasi permintaan, serta perubahan signifikan dalam kebijakan dan sistem manajemen stok. Dalam penelitian ini, data deret waktu yang awalnya direkam dalam frekuensi harian diubah menjadi frekuensi mingguan melalui proses resampling. Langkah ini merupakan bagian integral dari tahap pembersihan data (*data cleaning*), yang bertujuan untuk meningkatkan kualitas dan konsistensi data sebelum dilakukan analisis lebih lanjut. Proses resampling dari harian ke mingguan membantu dalam mengurangi fluktuasi acak yang sering muncul pada data harian, sehingga pola musiman dan tren jangka panjang menjadi lebih jelas terlihat. Selain itu, resampling juga memungkinkan penanganan terhadap nilai yang hilang dan penyelarasan data ke dalam interval waktu yang konsisten, yang merupakan prasyarat penting dalam analisis deret waktu seperti model *ARIMA* [20]. Data mingguan mengenai nilai *reorder point* selama dua tahun ditampilkan pada Tabel 2, yang memperlihatkan fluktuasi nilai dari minggu ke minggu.

Tabel 2. Data *Reorder Point*

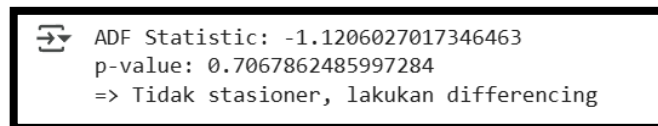
Year	Week	Value	Year	Week	Value
2023	1	30426	2024	1	40058
2023	2	31185	2024	2	40198
2023	3	31345	2024	3	39664
2023	4	31939	2024	4	40261
2023	5	32369	2024	5	39948
2023	6	32764	2024	6	39848
2023	7	33108	2024	7	39463
2023	8	32529	2024	8	38776
2023	9	32295	2024	9	38317
2023	10	32833	2024	10	38393
2023	11	32463	2024	11	39062
2023	12	33245	2024	12	38926
2023	13	32632	2024	13	39123
2023	14	33328	2024	14	39786
2023	15	33751	2024	15	39177
2023	16	33922	2024	16	39867
2023	17	33352	2024	17	40122
2023	18	33984	2024	18	40900
2023	19	34053	2024	19	41651
2023	20	33696	2024	20	41459
2023	21	34511	2024	21	41534
2023	22	35248	2024	22	40868
2023	23	35353	2024	23	40373
2023	24	35038	2024	24	40777
2023	25	35553	2024	25	41662
2023	26	35808	2024	26	42373
2023	27	35384	2024	27	42698
2023	28	35868	2024	28	43019
2023	29	35627	2024	29	43732
2023	30	36264	2024	30	43597
2023	31	35585	2024	31	44026
2023	32	35137	2024	32	44826
2023	33	35184	2024	33	44828
2023	34	35340	2024	34	44529
2023	35	36224	2024	35	44558
2023	36	35998	2024	36	45437

2023	37	36380	2024	37	44898
2023	38	36190	2024	38	44399
2023	39	36989	2024	39	44694
2023	40	36988	2024	40	44263
2023	41	37263	2024	41	44378
2023	42	36752	2024	42	44972
2023	43	37009	2024	43	44727
2023	44	36995	2024	44	45512
2023	45	37252	2024	45	46087
2023	46	37114	2024	46	46403
2023	47	38004	2024	47	45998
2023	48	38571	2024	48	46017
2023	49	38702	2024	49	45654
2023	50	39530	2024	50	45832
2023	51	39984	2024	51	46208
2023	52	40792	2024	52	46299
2023	53	40738	2024	53	45815

3.2 Uji Stasioneritas

Berdasarkan hasil uji *Augmented Dickey-Fuller (ADF)* pada **Gambar 2**, diperoleh nilai statistik uji sebesar -1.1206 dan *p-value* sebesar 0.7068. Nilai *p-value* yang lebih besar dari tingkat signifikansi 0.05 menunjukkan bahwa tidak terdapat cukup bukti untuk menolak hipotesis nol (*null hypothesis*) yang menyatakan bahwa data memiliki akar unit (*unit root*), sehingga dapat disimpulkan bahwa deret waktu tersebut bersifat tidak stasioner.


Ketidakstasioneran dalam deret waktu dapat menyebabkan masalah dalam pemodelan dan peramalan, karena asumsi dasar dari banyak model deret waktu, seperti *Autoregressive Integrated Moving Average (ARIMA)*, mengharuskan data yang digunakan bersifat stasioner. Oleh karena itu, untuk mengatasi masalah ini, dilakukan transformasi data melalui proses *differencing*, yaitu menghitung selisih antara nilai-nilai berturut-turut dalam deret waktu, guna menghilangkan tren dan membuat data menjadi stasioner. Proses *differencing* ini merupakan langkah umum dalam analisis deret waktu untuk memastikan bahwa data memenuhi asumsi stasioneritas, yang penting untuk validitas model dan akurasi peramalan.



Gambar 2. Hasil Uji *Stasioneritas*

3.3 Transformasi Data (Differencing/Log Transform)


Setelah dilakukan proses *first differencing*, dilakukan kembali uji *Augmented Dickey-Fuller (ADF)* untuk menguji stasioneritas data hasil transformasi. Hasil uji menunjukkan bahwa nilai statistik *ADF* sebesar -11.1742 dan *p-value* sebesar 2.59×10^{-20} , yang jauh lebih kecil dari tingkat signifikansi 0.05. Hal ini dengan tegas mengindikasikan bahwa hipotesis nol (*null hypothesis*) dapat ditolak, dan dengan demikian data setelah transformasi dinyatakan *stasioner*. Visualisasi pada **Gambar 3** secara jelas menunjukkan bahwa deret waktu hasil *differencing* tidak lagi memiliki pola tren yang jelas, yang merupakan ciri dari data *stasioner*. Proses ini sangat penting dilakukan karena model *Autoregressive Integrated Moving Average (ARIMA)* mensyaratkan data yang digunakan bersifat stasioner agar dapat memberikan hasil peramalan yang valid dan akurat.



Gambar 3. Hasil Uji *differencing*

3.4 Identifikasi Parameter (p, d, q) dengan ACF dan PACF

Setelah dilakukan transformasi menjadi stasioner melalui proses *first differencing*, analisis lanjutan dilakukan dengan menggunakan grafik *Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)* untuk menentukan ordo model *ARIMA* yang sesuai. Pada Gambar 4, grafik *ACF* menunjukkan bahwa korelasi hanya signifikan pada lag ke-1, dan selanjutnya berada dalam batas kepercayaan (*confidence interval*), yang mengindikasikan bahwa komponen *Moving Average (MA)* kemungkinan hanya diperlukan pada lag 1 ($q = 1$). Sementara itu, grafik *PACF* juga menunjukkan pola yang serupa, di mana hanya lag pertama yang signifikan, sehingga model *Autoregressive (AR)* dapat diasumsikan bernilai $p = 1$. Berdasarkan pola tersebut, model awal yang dapat dipertimbangkan adalah *ARIMA(1,1,1)* karena struktur data menunjukkan pola yang relatif stabil dan jelas.



Gambar 4. grafik ACF dan PACF

3.5 Membangun Model ARIMA

Berdasarkan Tabel 3, terlihat bahwa model *Autoregressive Integrated Moving Average (ARIMA)* (1,1,1) memiliki nilai *Akaike Information Criterion (AIC)* terendah dibandingkan dengan model-model lainnya, yaitu sebesar 1601.097. Oleh karena itu, model *ARIMA(1,1,1)* dipilih sebagai model terbaik untuk data yang dianalisis.

Pemilihan ordo model *ARIMA* dilakukan dengan mengevaluasi nilai *AIC* dari berbagai kombinasi parameter (p, d, q). Hasil evaluasi tersebut menunjukkan bahwa model dengan parameter (1,1,1) memberikan keseimbangan terbaik antara kompleksitas model dan kecocokan terhadap data.

Temuan ini juga sejalan dengan hasil analisis grafik *Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)* yang telah dilakukan sebelumnya. Grafik *ACF* menunjukkan penurunan signifikan pada lag pertama dan selanjutnya berada dalam batas kepercayaan, yang mengindikasikan keberadaan komponen *Moving Average (MA)* pada lag ke-1. Sementara itu, grafik *PACF* juga menunjukkan signifikansi pada lag pertama, mendukung keberadaan komponen *Autoregressive (AR)* pada lag ke-1.

Dengan demikian, baik secara visual melalui analisis *ACF* dan *PACF*, maupun secara kuantitatif berdasarkan nilai *AIC*, model *ARIMA(1,1,1)* terbukti paling sesuai untuk merepresentasikan pola data yang telah ditransformasikan menjadi stasioner melalui proses *differencing*.

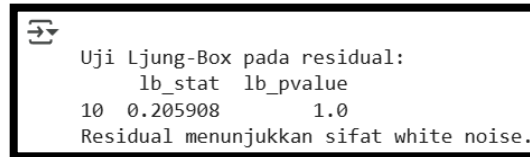
Tabel 3. Hasil Pengujian model ARIMA

No.	ARIMA Order (p,d,q)	AIC
1	(0, 0, 0)	2.085.305
2	(0, 0, 1)	1.956.467
3	(0, 0, 2)	1.864.756
4	(0, 1, 0)	1.605.259
5	(0, 1, 1)	1.606.153
6	(0, 1, 2)	1.607.112
7	(1, 0, 0)	1.629.808
8	(1, 0, 1)	1.631.807
9	(1, 0, 2)	1.631.651
10	(1, 1, 0)	1.606.002
11	(1, 1, 1)	1.601.097
12	(1, 1, 2)	1.602.986
13	(2, 0, 0)	1.631.806
14	(2, 0, 1)	1.632.976
15	(2, 0, 2)	1.632.707
16	(2, 1, 0)	1.606.653
17	(2, 1, 1)	1.602.978
18	(2, 1, 2)	1.601.951

3.6 Uji White Noise

Hasil uji Ljung-Box pada *residual* model Gambar 5 menunjukkan bahwa nilai statistik *Ljung-Box* sebesar 0.206 dengan $p\text{-value} = 1.0$. Karena nilai $p\text{-value} > 0.05$, maka tidak terdapat cukup bukti untuk menolak *hipotesis nol* bahwa *residual* tidak berkorelasi (bersifat acak).

Dengan demikian, *residual* dari model menunjukkan sifat *white noise*, yang menandakan bahwa model *ARIMA(1,1,1)* telah mampu menangkap pola dalam data secara memadai dan tidak menyisakan pola sistematis pada *residual*.



Uji Ljung-Box pada residual:		
lb_stat	lb_pvalue	
10	0.205908	1.0
Residual menunjukkan sifat white noise.		

Gambar 5. Hasil uji *White Noise*

3.7 Uji Signifikansi Parameter

Berdasarkan hasil *uji signifikansi* menggunakan model *ARIMA(1,1,1)* seperti yang ditampilkan pada Tabel 4, dapat disimpulkan bahwa:

- Hasil pemodelan terhadap data deret waktu menggunakan pendekatan *AutoRegressive Integrated Moving Average (ARIMA)*, model terbaik yang diperoleh adalah *ARIMA(1,1,1)*. Pemilihan ini didasarkan pada nilai *Akaike Information Criterion (AIC)* yang paling rendah, yaitu sebesar 1601.097, dibandingkan model-model lain yang diuji dalam penelitian ini.
- Seluruh parameter dalam model *ARIMA(1,1,1)* signifikan secara statistik, dengan nilai $p\text{-value} < 0.05$. Nilai koefisien *ar.L1* sebesar 0.9994 dan *ma.L1* sebesar -0.9949 menunjukkan bahwa model memiliki komponen *autoregressive* dan *moving average* yang kuat dalam menjelaskan variasi data deret waktu secara keseluruhan.
- Evaluasi diagnostik residual menunjukkan bahwa model memenuhi asumsi dasar:
- Hasil *Ljung-Box test* pada lag-1 memberikan $p\text{-value}$ sebesar 0.30 (> 0.05), yang mengindikasikan tidak terdapat autokorelasi pada residual (*white noise*).
- Uji *heteroskedastisitas* menunjukkan $p\text{-value}$ sebesar 0.86, menandakan tidak adanya pola perubahan varians, atau residual bersifat *homoskedastik*.
- Meskipun uji *Jarque-Bera* menghasilkan $p\text{-value}$ sebesar 0.03, yang menunjukkan residual tidak sepenuhnya berdistribusi normal, namun ketidaksesuaian ini masih dalam batas toleransi yang dapat diterima dalam konteks model *ARIMA*.
- Dengan demikian, model *ARIMA(1,1,1)* dapat dianggap layak dan cukup optimal untuk digunakan dalam proses peramalan data ini serta memberikan hasil yang andal dalam analisis deret waktu jangka pendek maupun menengah.

Tabel 4. Hasil Uji Signifikansi Parameter

Dep. Variable:	Value	No. Observations:	106
Model:	ARIMA(1, 1, 1)	Log Likelihood	-797.548
Date:	Sat, 17 May 2025	AIC	1601.097
Time:	04:39:23	BIC	1609.059
Sample:	0	HQIC	1604.323
	- 106		
Covariance Type:	opg		
	coef	std err	z
ar.L1	0.9994	0.011	90.673
ma.L1	-0.9949	0.052	-19.028
sigma2	2.316e+05	9.79e-09	2.37e+13
Ljung-Box (L1) (Q):	1.08	Jarque-Bera (JB):	6.98
Prob(Q):	0.30	Prob(JB):	0.03
Heteroskedasticity (H):	0.94	Skew:	-0.14
Prob(H) (two-sided):	0.86	Kurtosis:	1.77

3.8 Uji MAPE (Mean Absolute Percentage Error)


Model *ARIMA(1,1,1)* menunjukkan performa yang sangat baik dengan nilai *Mean Absolute Percentage Error (MAPE)* sebesar 0.02%. Berdasarkan nilai *MAPE* pada Gambar 6, model ini termasuk dalam kategori *sangat akurat*. Hal ini menunjukkan bahwa hasil prediksi sangat mendekati nilai aktual, sehingga model ini dapat diandalkan untuk melakukan *forecasting* pada tahap selanjutnya. Nilai *MAPE* yang rendah menunjukkan bahwa model tidak hanya cocok untuk data pelatihan, tetapi juga memiliki kinerja yang baik pada data yang tidak terlihat sebelumnya.



Gambar 6. Hasil uji *MAPE* pada Model (1,1,1)

3.9 forecasting

Berdasarkan Gambar 7, ditampilkan hasil peramalan (*forecasting*) menggunakan model *ARIMA*(1,1,1). Pada grafik tersebut, garis berwarna biru merepresentasikan data historis yang tercatat sejak Januari 2023 hingga tahun 2024, sedangkan garis berwarna merah menunjukkan hasil prediksi nilai di masa yang akan datang (tahun 2025) berdasarkan model tersebut. Secara keseluruhan, data historis menunjukkan tren kenaikan yang konsisten meskipun terdapat fluktuasi musiman yang cukup signifikan. Model *ARIMA*(1,1,1) digunakan karena mampu menangkap karakteristik pola data secara memadai, termasuk tren dan komponen acak. Hasil peramalan menunjukkan adanya kenaikan yang berlanjut di tahun 2025, sebagaimana terlihat dari garis merah yang terus meningkat. Ini mengindikasikan bahwa model memprediksi tren pertumbuhan yang stabil untuk periode tersebut. Selain itu, berdasarkan uji *Ljung-Box*, residual dari model bersifat *white noise* (acak) dengan p-value sebesar 1.0, yang menandakan bahwa tidak ada pola yang tertinggal dalam residual. Hal ini menguatkan bahwa model *ARIMA*(1,1,1) telah sesuai dan mampu merepresentasikan struktur data dengan sangat baik.



Gambar 7. Hasil uji *forecasting* pada Model (1,1,1)

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model *ARIMA*(1,1,1) mampu memberikan hasil peramalan yang cukup baik terhadap data deret waktu yang dianalisis. Data historis yang menunjukkan tren kenaikan dengan adanya fluktuasi musiman dapat direpresentasikan secara memadai oleh model ini. Dengan mengidentifikasi bahwa data memerlukan satu kali proses diferensiasi untuk mencapai stasioneritas, serta adanya keterkaitan antara nilai masa lalu dan kesalahan peramalan sebelumnya, model *ARIMA*(1,1,1) dipilih karena mampu menangkap dinamika tersebut secara efektif. Validitas model diperkuat dengan uji *Ljung-Box*, yang menunjukkan bahwa residual dari model bersifat acak (*white noise*), sehingga tidak terdapat pola sistematis yang tertinggal. Hal ini menunjukkan bahwa model telah mengakomodasi pola data yang ada dan dapat digunakan sebagai dasar untuk melakukan peramalan ke depan. Hasil *forecasting* juga menunjukkan tren kenaikan yang berkelanjutan hingga tahun 2025, yang mengindikasikan potensi pertumbuhan pada objek yang diteliti. Meskipun demikian, penelitian ini memiliki keterbatasan yang perlu diperhatikan. Salah satunya adalah model *ARIMA* tidak mempertimbangkan variabel eksternal yang mungkin berpengaruh terhadap nilai masa depan. Selain itu, fluktuasi mendadak akibat kejadian luar biasa atau perubahan struktural dalam data tidak dapat ditangkap secara optimal oleh model ini. Oleh karena itu, untuk penelitian selanjutnya, disarankan agar mempertimbangkan penggunaan model yang lebih kompleks yang mampu mengakomodasi lebih banyak variabel dan dinamika yang lebih kompleks. Dengan demikian, akurasi dan ketahanan model dalam menghadapi data yang lebih beragam dapat ditingkatkan.

REFERENCES

- [1] J. Ekonomi, M. dan Akuntansi, K. Ilyas, and D. Eko Waluyo, "Neraca", [Online]. Available: <http://jurnal.kolibi.org/index.php/neraca>

- [2] N. Novyta, L. Alhazami, and L. @mncu A. Id, "PERAMALAN PERMINTAAN PRODUK NATA DE COCO DALAM SUPPLY CHAIN MANAGEMENT DENGAN MODEL ARIMA," vol. 7, no. 2, 2022.
- [3] L. Hablinawati and J. Nugraha, "Peramalan Nilai Tukar Petani di Daerah Istimewa Yogyakarta Menggunakan Metode ARIMA," *Emerging Statistics and Data Science Journal*, vol. 2, no. 1, 2024.
- [4] M. Alfian et al., "Peramalan Harga Saham PT. Bank Central Asia, Tbk Menggunakan Metode ARIMA," *Jurnal Derivat*, vol. 11, no. 1, 2024, [Online]. Available: <https://finance.yahoo.com>.
- [5] Muh. Qodri, U. Mukhaiyar, V. Ananda, and S. Maisaroh, "Comparison of Stock Prediction Using ARIMA Model with Multiple Interventions of Step and Pulse Functions," *Jurnal Ilmiah Sains*, pp. 1–16, Mar. 2024, doi: 10.35799/jis.v24i1.51269.
- [6] Maya Sari Wahyuni, A. Zaki, S. Hidayat, and M. I. Pratama, "Penerapan Metode ARIMA dalam Meramalkan Kebutuhan Energi Listrik di Kota Makassar," *Journal of Mathematics, Computations and Statistics*, vol. 7, no. 2, pp. 323–331, Oct. 2024, doi: 10.35580/jmathcos.v7i2.4388.
- [7] L. A. Hayati and N. Agustina, "Aplikasi Model ARIMA dalam Peramalan Produk Domestik Regional Bruto (PDRB) Pertambangan dan Penggalian Kalimantan Selatan (Application of ARIMA Model in Forecasting Gross Regional Domestic Product (GRDP) Mining and Quarrying in South Kalimantan)."
- [8] L. Hablinawati and J. Nugraha, "Peramalan Nilai Tukar Petani di Daerah Istimewa Yogyakarta Menggunakan Metode ARIMA," *Emerging Statistics and Data Science Journal*, vol. 2, no. 1, 2024.
- [9] F. Rizki Kurniawan and R. Sutomo, "Forecasting Rice Inventory in Indonesia Using the ARIMA Algorithm Method," Kurniawan and Sutomo, 2021. [Online]. Available: www.jmis.site
- [10] R. Hardianto, "PERAMALAN PENJUALAN TEH HIJAU DENGAN METODE ARIMA (STUDI KASUS PADA PT. MK)."
- [11] S. Schima Wulandari and S. Yurinanda, "Penerapan Metode ARIMA Dalam Memprediksi Fluktuasi Harga Saham PT Bank Central Asia Tbk," 2021. [Online]. Available: www.finance.yahoo.com.
- [12] E. I. Sihombing, C. D. Suhendra, and L. F. Marini, "KLIK: Kajian Ilmiah Informatika dan Komputer Analisis Data Time Series Untuk Prediksi Harga Komoditas Pangan Menggunakan Autoregressive Integrated Moving Average," *Media Online*, vol. 4, no. 6, 2024, doi: 10.30865/klik.v4i6.1863.
- [13] Ritus Santra, "Uji Stasioneritas dalam Deret Waktu — Uji Dickey Fuller & Uji Dickey Fuller Tertambah (ADF)," <https://medium.com/@ritusantra/tests-for-stationarity-in-time-series-dickey-fuller-test-augmented-dickey-fuller-adf-test-d2e92e214360>.
- [14] R. J. A. G. Hyndman, "Forecasting: Principles and Practice," <https://otexts.com/fpp2/stationarity.html>.
- [15] C. SIMANJUNTAK, W. SYAFMEN, and G. Z, "PEMODELAN ARIMA UNTUK PERAMALAN PERMINTAAN EKSPOR KARET DI PT. HOK TONG JAMBI," *E-Jurnal Matematika*, vol. 13, no. 2, p. 154, May 2024, doi: 10.24843/mtk.2024.v13.i02.p456.
- [16] J. E. Saputra and W. Febrianti, "Application of Autoregressive Integrated Moving Average (ARIMA) for Forecasting Inflation Rate in Indonesia," *Jurnal Matematika, Statistika dan Komputasi*, vol. 21, no. 2, pp. 382–396, Jan. 2025, doi: 10.20956/j.v21i2.36609.
- [17] "1. Bu Halwa 15 Eks, B5".
- [18] D. A. Pallupi, T. Tamo, and A. Rusgiyono, "PERAMALAN HARGA GULA PASIR MENGGUNAKAN VARIASI KALENDER REGARIMA DENGAN MOVING HOLIDAY EFFECT (PERIODE JANUARI 2018 SAMPAI DENGAN DESEMBER 2022 DI PASAR KOTA SEMARANG)," *Jurnal Gaussian*, vol. 13, no. 1, pp. 230–239, Oct. 2024, doi: 10.14710/j.gauss.13.1.230-239.
- [19] M. Azman Maricar, "Analisa Perbandingan Nilai Akurasi Moving Average dan Exponential Smoothing untuk Sistem Peramalan Pendapatan pada Perusahaan XYZ".
- [20] James Ho, "Time Series Data Analysis – Resample," <https://towardsdatascience.com/time-series-data-analysis-resample-1ff2224edec9/>.