

ANALISIS MODEL SARIMA DALAM PERAMALAN PENJUALAN RITEL MOBIL BEKAS BERDASARKAN DATA PENJUALAN BULANAN DI AMERIKA SERIKAT

Analysis of The Sarima Model in Forecasting Used Car Retail Sales Based on Monthly Sales Data in The United States

Moch Yahya¹, Nurmawati Ainun², Nurul Hikmah³, Al Aghni Naufalia⁴, Ihsan Fathoni Amri^{5,a}, M. Al Haris⁶

¹Universitas Muhammadiyah Semarang [Email: mochammadyahya002@gmail.com]

²Universitas Muhammadiyah Semarang [Email: nurmawati.ainun.h@gmail.com]

³Universitas Muhammadiyah Semarang [Email: nrlhikmahh12@gmail.com]

⁴Universitas Muhammadiyah Semarang [Email: alaghninaufalia@gmail.com]

⁵Universitas Muhammadiyah Semarang [Email: ihsanfathoni@unimus.ac.id]

⁶Universitas Muhammadiyah Semarang [Email: alharis@unimus.ac.id]

^aihsanfathoni@unimus.ac.id

ABSTRAK

Penelitian ini bertujuan untuk meramalkan penjualan ritel mobil bekas di Amerika Serikat dengan menggunakan model Seasonal Autoregressive Integrated Moving Average (SARIMA). Data yang digunakan bersumber dari Federal Reserve Bank of St. Louis (FRED) dengan periode Januari 2019 hingga Desember 2024, memiliki karakteristik musiman dan dianalisis menggunakan bahasa pemrograman R. Model SARIMA dipilih karena mampu menangkap komponen musiman yang tidak dapat dimodelkan secara eksplisit oleh ARIMA. Prosedur dimulai dari analisis stasioneritas hingga pemilihan model terbaik berdasarkan nilai Akaike Information Criterion (AIC) dan uji diagnostik residual. Hasil penelitian menunjukkan bahwa model SARIMA(0,1,2)(1,1,0)¹² adalah model terbaik dengan nilai AIC sebesar 802.87 dan MAPE yang menunjukkan tingkat akurasi sangat baik. Model ini menghasilkan peramalan penjualan selama 12 bulan ke depan dengan pola fluktuatif musiman, di mana penjualan tertinggi diprediksi terjadi pada bulan Maret dan terendah pada bulan Desember.

Kata kunci: Peramalan, SARIMA, Penjualan Mobil Bekas, Deret Waktu, Musiman.

ABSTRACT

This study aims to forecast used car retail sales in the United States using the Seasonal Autoregressive Integrated Moving Average (SARIMA) model. The data used is sourced from the Federal Reserve Bank of St. Louis (FRED) with a period of January 2019 to December 2024, has seasonal characteristics and is analyzed using the R programming language. The SARIMA model was chosen because it is able to capture seasonal components that cannot be modeled explicitly by ARIMA. The procedure starts from stationarity analysis to the selection of the best model based on the Akaike Information Criterion (AIC) value and residual diagnostic tests. The results show that the SARIMA (0,1,2) (1,1,0)¹² model is the best model with an AIC value of 802.87 and MAPE which shows a very good level of accuracy. This model produces sales forecasting for the next 12 months with a seasonal fluctuating pattern, where the highest sales are predicted to occur in March and the lowest in December.

Keywords: Forecasting, SARIMA, Used Car Sales, Time Series, Seasonal.

1. PENDAHULUAN

Analisis deret waktu merupakan salah satu pendekatan statistik yang sangat penting dalam memahami perilaku data yang dikumpulkan secara berurutan sepanjang kurun waktu tertentu. Salah satu komponen kunci dalam analisis ini adalah pola musiman (*seasonality*), yaitu fluktuasi data yang muncul secara berulang pada periode tertentu, seperti harian, mingguan, bulanan, atau tahunan [1]. Pola musiman ini dapat ditemukan dalam berbagai bidang, mulai dari cuaca dan ekonomi, hingga perilaku konsumsi masyarakat. Sebagai contoh, peningkatan penjualan produk retail mobil bekas di Amerika Serikat pada periode tertentu dalam setahun sering kali mencerminkan pola musiman yang signifikan [2]. Pola-pola seperti ini, apabila tidak dimodelkan dengan tepat, dapat menyebabkan analisis deret

waktu menjadi bias dan tidak mencerminkan realitas data secara akurat.

Permasalahan utama dalam konteks ini adalah keterbatasan model deret waktu konvensional dalam menangkap pola musiman secara eksplisit. Salah satu model yang umum digunakan, yaitu ARIMA (*Autoregressive Integrated Moving Average*), meskipun cukup efektif dalam memodelkan proses stasioner dan tren jangka panjang, tidak dirancang untuk menangani fluktuasi musiman yang berulang [3]. Akibatnya, jika pola musiman tidak diperhitungkan, hasil peramalan menjadi tidak akurat dan dapat menyesatkan proses pengambilan keputusan, terutama dalam konteks bisnis atau kebijakan yang berbasis data historis.

Oleh karena itu, urgensi untuk memodelkan pola musiman dalam deret waktu menjadi semakin tinggi, khususnya ketika data menunjukkan fluktuasi berkala yang konsisten. Ketidakmampuan dalam mengakomodasi pola ini dapat menyebabkan estimasi kebutuhan yang keliru, perencanaan yang tidak tepat, serta peningkatan risiko dalam manajemen sumber daya dan strategi organisasi. Dalam dunia bisnis, kesalahan dalam memprediksi permintaan musiman bisa berdampak pada kerugian finansial yang signifikan, sementara dalam konteks publik, dapat mengganggu efektivitas program kebijakan yang dirancang [4].

Penelitian ini akan menggunakan data deret waktu yang dikumpulkan secara periodik, dengan karakteristik yang memungkinkan munculnya pola musiman. Salah satu contohnya adalah data penjualan bulanan mobil bekas di Amerika Serikat dalam beberapa tahun terakhir. Data ini menjadi relevan karena disusun secara konsisten dalam interval waktu tertentu, sehingga memungkinkan identifikasi dan analisis pola musiman secara lebih akurat. Ketersediaan data historis yang memadai juga memungkinkan pengujian model peramalan dengan pendekatan statistik yang lebih robust.

Sebagai studi kasus, fenomena musiman pada penjualan mobil bekas di Amerika Serikat memberikan gambaran yang konkret. Lonjakan penjualan pada bulan-bulan tertentu, seperti menjelang musim liburan atau awal tahun, kerap kali dipengaruhi oleh promosi besar-besaran, perubahan kebutuhan transportasi, serta pola konsumsi masyarakat. Fluktuasi ini bukanlah kejadian acak, melainkan pola berulang yang mencerminkan efek musiman yang kuat. Jika pola ini tidak dikenali dan tidak dimasukkan dalam model peramalan, hasilnya akan jauh dari representatif dan dapat memicu kesalahan dalam estimasi permintaan atau manajemen stok.

Untuk menjawab permasalahan tersebut, pendekatan yang lebih tepat adalah dengan menerapkan model *Seasonal ARIMA* (SARIMA), yakni pengembangan dari model ARIMA yang menyertakan parameter musiman dalam struktur modelnya. SARIMA dirancang untuk menangkap pola musiman yang berulang pada interval tertentu, sehingga lebih efektif dalam menganalisis dan memprediksi data dengan komponen musiman yang kuat [5]. Dengan keunggulan tersebut, SARIMA memberikan peluang untuk menghasilkan peramalan yang lebih akurat, meningkatkan pemahaman terhadap dinamika data, dan mendukung pengambilan keputusan yang lebih informasional.

Dengan demikian, pemahaman dan penerapan model SARIMA bukan hanya menjadi alternatif teknis dari ARIMA, tetapi juga merupakan langkah strategis dalam mengatasi permasalahan musiman pada analisis deret waktu. Pendekatan ini akan membantu memaksimalkan kualitas analisis dan prediksi yang dihasilkan, sekaligus memperkuat dasar pengambilan keputusan berbasis data historis yang lebih akurat dan relevan dengan dinamika periodik yang nyata.

2. METODE PENELITIAN

2.1. Sumber dan Karakteristik Data

Data yang digunakan merupakan data sekunder, yaitu data penjualan ritel mobil bekas yang diperoleh melalui situs resmi Federal Reserve Bank of St. Louis (FRED). Data tersebut mencakup periode Januari 2019 hingga Desember 2024 dengan frekuensi bulanan dan telah disesuaikan terhadap pola musiman (*seasonally adjusted*). Karena memiliki karakteristik runtun waktu, data ini dianalisis dalam bentuk time series menggunakan bahasa pemrograman R. Seluruh proses pengolahan dilakukan melalui platform Google Colaboratory yang mendukung integrasi kode secara interaktif di lingkungan komputasi awan.

2.2. Model SARIMA

SARIMA merupakan model yang dikembangkan dari *Autoregressive Integrated Moving Average* (ARIMA). *Model Seasonal Autoregressive Integrated Moving Average* (SARIMA) digunakan ketika terdapat fluktuasi data yang berulang secara periodik, misalnya setiap tahun, triwulan, bulan, minggu, atau bahkan hari [6]. *Seasonal Autoregressive Integrated Moving Average* (SARIMA) terdiri dari model AR (p), MA (q), ARMA (p,q), ARIMA (p,d,q), lalu SARIMA (p,d,q) (P,D,Q)s. Dimana P adalah nilai AR dari plot PACF data non musiman, d adalah nilai *differencing* data non musiman, Q adalah nilai *differencing* data musiman, dan D adalah nilai AR dari plot PACF data musiman [7]. SARIMA adalah model yang di bentuk dari komponen musiman dan non-musiman.


Untuk membentuk model SARIMA dilakukan beberapa tahap yaitu, pengecekan stasioner, uji normalitas, dan uji residual untuk mengetahui apakah ada p-value white-noise. SARIMA memiliki bentuk umum yang didefinisikan sebagai berikut [8]:

$$\phi_p(B)\phi_p(B)^s(1-B)^d(1-B^s)^D Z_t = \theta_q(B)\theta_Q(B^s)\varepsilon_t$$

Dimana:

$\phi_p(B)$	: AR non-musiman dengan orde p
$\phi_p(B)^s$	: AR musiman dengan orde p
$(1-B)^d$	: <i>Differencing</i> non-musiman dengan orde d
$(1-B^s)^D$	: <i>Differencing</i> musiman dengan orde D
Z_t	: Nilai prediksi variable dependen pada waktu ke-t
$\theta_q(B)$	: Koefisien MA non-musiman dengan orde q
$\theta_Q(B^s)$	: Koefisien MA musiman dengan orde Q
ε_t	: <i>White noise</i>

2.3. Tahapan Analisis



Gambar 1 flowchart Metode SARIMA

Langkah-langkah yang dilakukan untuk mendapatkan model seasonal ARIMA (SARIMA) pada kasus data penjualan ritel mobil bekas dari periode Januari 2019 hingga Desember 2024 adalah sebagai berikut:

1. Pengumpulan data penjualan ritel mobil bekas, Januari 2019 sampai Desember 2024

2. Identifikasi plot deret waktu untuk mengamati tren dan pola musiman, serta analisis deskriptif.
3. Split data menjadi dua bagian, yaitu data *training* dan *data testing*
4. Identifikasi Stasioneritas data dengan variansi dan *mean* kemudian uji ADF. Gunakan transformasi Box-Cox untuk variansi tidak stabil, *differencing* non-musiman untuk *mean* tidak stasioner, dan *differencing* musiman jika ada pola musiman.
5. Identifikasi model sementara yang telah stasioner dengan menganalisis plot ACF dan PACF terhadap data yang telah *didifferencing*.
6. Uji signifikansi model SARIMA yang dievaluasi berdasarkan signifikansi parameter (p -value $< 0,05$).
7. Uji diagnostik model untuk memastikan residual model memenuhi asumsi *white noise* dan normalitas
8. Pemilihan model terbaik dengan menetapkan model SARIMA $[(p,d,q)(P,D,Q)^S]$ terbaik untuk peramalan berdasarkan nilai AIC terkecil.
9. Melakukan forecasting pada data penjualan ritel mobil bekas dari periode Januari 2019 hingga Desember 2024.
10. Evaluasi keakuratan peramalan dilakukan dengan menghitung MAPE.
Tingkat akurasi model dievaluasi menggunakan *Mean Absolute Percentage Error* (MAPE). MAPE adalah ukuran yang digunakan untuk mengetahui seberapa besar kesalahan prediksi model dibandingkan dengan nilai aktual, dalam bentuk persentase. Semakin kecil nilai MAPE, maka semakin baik akurasi model. Kriteria Penilaian MAPE sebagai berikut: [9]

Tabel 1 Kriteria nilai MAPE


Nilai MAPE	Kriteria
$<10\%$	Sangat Baik
$10\% - 20\%$	Baik
$20\% - 50\%$	Cukup
$>50\%$	Buruk

3. HASIL DAN PEMBAHASAN

3.1. Eksplorasi Data

Data yang digunakan berasal dari penjualan ritel mobil bekas yang diperoleh melalui situs resmi *Federal Reserve Bank of St. Louis* (FRED). Data tersebut mencakup periode Januari 2019 hingga Desember 2024 dengan frekuensi bulanan dan telah disesuaikan terhadap pola musiman (*seasonally adjusted*). Karena memiliki karakteristik runtun waktu, data ini dianalisis dalam bentuk *time series* menggunakan bahasa pemrograman R. Seluruh proses pengolahan dilakukan melalui platform *Google Colaboratory* yang mendukung integrasi kode secara interaktif di lingkungan komputasi awan.

Berikut merupakan plot data penjualan ritel mobil bekas pada penelitian ini.



Gambar 2 Plot *Seasonal Data*

Berdasarkan Gambar 2 dapat dilihat pola data penjualan ritel mobil bekas bersifat tidak stasioner, data tersebut bersifat musiman. Pola musiman ini dapat diidentifikasi dari data yang menunjukkan fluktuasi naik dan turun yang berulang dalam interval waktu yang konsisten.

Tabel 2 Nilai Rata-Rata

Analisis	Nilai
Rata-rata	11.093
Median	11.472
Standar Deviasi	2.016,58
Maksimum	15.309
Minimum	5.497

Berdasarkan Tabel 2, menunjukkan nilai rata-rata data penjualan ritel mobil bekas sebesar 11.093 yang dapat dikategorikan sebagai kenaikan musiman penjualan ritel mobil bekas. Selain itu, memiliki nilai median sebesar 11.472, standar deviasi sebesar 2.016,58, penjualan tertinggi sebesar 15.309 juta dollar, dan penjualan terendah sebesar 5.497 juta dollar.

3.2. Model SARIMA

Data *penjualan* ritel mobil bekas dibagi menjadi dua bagian untuk keperluan pemodelan dan evaluasi, yaitu data latih dan data uji. Data latih mencakup periode Januari 2019 hingga Desember 2023, dan digunakan untuk membangun serta mengestimasi model SARIMA. Sementara itu, data uji mencakup periode Januari 2024 hingga Desember 2024, dan digunakan untuk mengevaluasi kemampuan model dalam melakukan peramalan terhadap data di luar sampel pelatihan. Pembagian ini dilakukan dengan mempertimbangkan kesinambungan runtun waktu agar model dapat merepresentasikan pola historis secara akurat dalam melakukan proyeksi ke masa mendatang.

Pemeriksaan stasioneritas dalam rata-rata juga dapat dilakukan dengan *Augmented Dickey Fuller* (ADF) test pada data latih penjualan ritel mobil bekas (Januari 2019 – Desember 2023).

Hipotesis

H_0 : Data tidak stasioner

H_1 : Data stasioner

Daerah penolakan H_0 adalah jika nilai $p\text{-value} < \alpha$ dengan nilai $\alpha = 0,05$. Berdasarkan hasil uji ADF diperoleh nilai $p\text{-value}$ sebesar 0.2714. Dengan menggunakan tingkat kepercayaan 95% dapat ditarik kesimpulan bahwa data yang ada gagal tolak H_0 yang artinya data penjualan ritel mobil bekas tidak stasioner (mengandung unit root).

Untuk mengatasi masalah tersebut data perlu dilakukan *differencing*. Untuk menghasilkan data yang stasioner dilakukan *differencing* non-musiman ($d=1$) dan untuk menghilangkan kuatnya pengaruh musiman dilakukan *differencing* sekali musiman ($D=1$).


Dari hasil uji ADF setelah melakukan *differencing* non-musiman, diperoleh $p\text{-value}$ sebesar 0,01 yang mana lebih kecil dari 0,05. Sehingga hasil akhir dari hipotesis dengan menggunakan tingkat kepercayaan 95%, diperoleh data yang ada tolak H_0 . Artinya Data Penjualan Ritel Mobil Bekas sudah stasioner dalam rata-rata. Walaupun data sudah stasioner, selanjutnya perlu dicek kestasioneran data musimannya.

Dari hasil uji ADF setelah melakukan *differencing* musiman, diperoleh $p\text{-value}$ sebesar 0,01 yang mana lebih kecil dari 0,05. Sehingga hasil akhir dari hipotesis dengan menggunakan tingkat kepercayaan 95%, diperoleh data yang ada tolak H_0 . Artinya Data latih Penjualan Ritel Mobil Bekas setelah dilakukan *differencing* musiman adalah stasioner (tidak mengandung unit root).

Setelah didapatkan data telah stasioner, selanjutnya dilakukan identifikasi model SARIMA dengan susunan $(p, d, q)(P, D, Q)^s$ kemudian plotkan data penjualan ritel mobil bekas yang telah di *differencing* ke dalam plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).

Grafik ACF biasanya ditampilkan dalam bentuk barplot, di mana tinggi batang menunjukkan kekuatan korelasi untuk setiap lag. Pola ACF dapat membantu mengidentifikasi apakah data mengandung komponen musiman, tren, atau non-stasioner. Salah satu indikasi data tidak stasioner adalah ketika nilai ACF meluruh secara lambat (slow decay), terutama pada lag awal. Sebaliknya, pada data stasioner, nilai ACF akan turun dengan cepat dan cenderung mendekati nol setelah beberapa lag.

Partial Autocorrelation Function (PACF) mengukur korelasi antara dua titik dalam deret waktu dengan mengontrol efek dari lag-lag di antaranya. Adanya pengaruh dalam data ditunjukkan oleh terputusnya plot PACF pada nilai lag signifikan di sekitar nol. Ordo p dalam model ARIMA (p, d, q) ditentukan berdasarkan pola yang tampak pada plot PACF [10].



Gambar 3.a

Gambar 3.b

Gambar 3.c

Gambar 3.d

Gambar 3 Plot ACF dan PACF sesudah Differencing

Berdasarkan Gambar 3.a, yaitu plot ACF data non-musiman, terlihat adanya dua lag signifikan yang keluar dari batas signifikan, sehingga menunjukkan kemungkinan orde $MA(q)$ sebesar 2. Sedangkan dari Gambar 3.b, yaitu plot PACF data non-musiman, terdapat satu lag signifikan yang keluar batas, sehingga menunjukkan kemungkinan orde $AR(p)$ sebesar 1. Nilai $d=1$ digunakan karena telah

dilakukan *differencing* satu kali terhadap data non-musiman untuk menghilangkan tren.

Selanjutnya, dari Gambar 3.c dan 3.d yang menunjukkan ACF dan PACF terhadap data yang telah dilakukan *differencing* musiman, diperhatikan pola pada lag musiman (kelipatan 12). Pada Gambar 3.c (ACF musiman), terdapat satu lag signifikan pada lag ke-12 yang menunjukkan kemungkinan adanya komponen musiman MA(Q=0), karena tidak ada lonjakan yang signifikan. Namun, dari Gambar 3.d (PACF musiman), terlihat adanya satu lonjakan signifikan pada lag ke-12, yang menunjukkan adanya komponen musiman AR dengan orde 1. Nilai D=1 diambil karena telah dilakukan *differencing* musiman satu kali untuk mengatasi pola musiman.

Berdasarkan hasil identifikasi awal, diperoleh dugaan awal model utama yaitu SARIMA(1,1,2)(1,1,1)¹². Model ini kemudian dikembangkan menjadi beberapa alternatif model dengan kombinasi orde lebih sederhana untuk mendapatkan model dengan kriteria informasi (AIC dan BIC) terbaik. Evaluasi dilakukan terhadap 6 model kandidat sebagaimana ditunjukkan pada tabel berikut:

Tabel 3 Model SARIMA Sementara

No	Model	Parameter
1	SARIMA (1,1,1)(1,1,1) ¹²	AR1 MA1 SAR1 SMA1
2	SARIMA (1,1,0)(1,1,0) ¹²	AR1 SAR1
3	SARIMA (0,1,1)(0,1,1) ¹²	MA1 SMA1
4	SARIMA (1,1,1)(0,1,1) ¹²	AR1 MA1 SMA1
5	SARIMA (0,1,2)(1,1,0) ¹²	MA1 MA2 SAR1
6	SARIMA (1,1,0)(0,1,1) ¹²	AR1 SMA1

Estimasi model SARIMA dapat dilakukan dengan menguji apakah parameter dari kombinasi model yang terbentuk sudah signifikan atau tidak. Parameter dikatakan signifikan apabila memiliki p-value < taraf signifikan 0,05.

Tabel 4 Estimasi dan Uji Signifikansi Parameter Model

No	Model	Parameter	Estimasi	P-Value	Keputusan
1	SARIMA (1,1,1)(1,1,1) ¹²	AR1	-0.781047	3.839e-16	Signifikan
		MA1	0.958164	2.2e-16	Signifikan
		SAR1	-0.758492	2.2e-16	Signifikan
		SMA1	0.930386	9.384e-06	Signifikan
2	SARIMA (1,1,0)(1,1,0) ¹²	AR1	-0.033249	0.8199	Tidak Signifikan
		SAR1	-0.588623	2.874e-09	Signifikan

3	SARIMA (0,1,1)(0,1,1) ¹²	MA1	0.082132	0.699	Tidak Signif- ikan
		SMA1	-1.149921	2e-16	Signifikan
4	SARIMA (1,1,1)(0,1,1) ¹²	AR1	0.584820	1.443e-10	Signifikan
		MA1	-0.884088	1.304e-11	Signifikan
		SMA1	-1.170069	2.2e-16	Signifikan
5	SARIMA (0,1,2)(1,1,0) ¹²	MA1	-0.00956470	0.0409578	Signifikan
		MA2	-0.46497280	0.0001746	Signifikan
		SAR1	-0.60909921	1.183e-09	Signifikan
6	SARIMA (1,1,0)(0,1,1) ¹²	AR1	0.020354	0.8901	Tidak Signif- ikan
		SMA1	-1.138888	2e-16	Signifikan

Model yang memiliki $p\text{-value} < 0,05$ yang artinya lolos uji signifikansi. Dari tabel 4 diperoleh tiga model yang semua parameternya signifikan yaitu model SARIMA (1,1,1)(1,1,1)¹², SARIMA (1,1,1)(0,1,1)¹², dan SARIMA (0,1,2)(1,1,0)¹². Selanjutnya ketiga model tersebut dilakukan uji diagnostik yaitu uji asumsi *white noise* dan uji kenormalan.

Uji diagnostik model dilakukan untuk mengetahui apakah residual model adalah *white noise* atau tidak. Untuk mengetahui adanya pengaruh signifikan terhadap data deret waktu, dilakukan uji signifikansi terhadap parameter-parameter yang diestimasi dalam model SARIMA. Untuk memeriksa kesesuaian model yang telah diidentifikasi, diagnosis model dilakukan. Diagnosis ini didasarkan pada analisis residual, yang memeriksa kebebasan sisaan dan kenormalan sisaan [11].

Uji diagnostik model terdiri dari uji asumsi *white noise* dan uji normalitas. Model yang residualnya tidak memiliki autokorelasi disebut *white noise*. Pengujian asumsi *white noise* pada model menggunakan uji *Ljung-Box*. Hipotesis yang dipakai yaitu hipotesis nol (H_0) diterima dan model *white noise* memenuhi, apabila uji *Ljung-Box* menghasilkan $p\text{-value} >$ taraf signifikan 0,05.

Tabel 5 Uji Ljung-Box

Model	$x\text{-squared}$	P-value
SARIMA (1,1,1)(1,1,1) ¹²	0.81557	0.3665
SARIMA (1,1,1)(0,1,1) ¹²	1.6629	0.1972
SARIMA (0,1,2)(1,1,0) ¹²	0.088759	0.7658

Berdasarkan tabel 5 diperoleh bahwa keempat model tersebut berhasil menerima hipotesis nol (H_0) dan keempat model memenuhi asumsi *white noise* karena $p\text{-value} >$ taraf signifikan 0,05. Dilanjutkan dengan uji normalitas.

Dimana lag maksimum ditetapkan sebagai K_{maks} , sedangkan p dan q mewakili orde dari model ARMA (p, q). dalam proses pemilihan model alternatif dengan nilai *Akaike Information Criterion* (AIC) paling rendah dianggap sebagai model yang paling sesuai [12].

Pengujian residual distribusi normal pada model menggunakan statistik Uji *Shapiro-Wilk* dengan hipotesis sebagai berikut.

H_0 : $F(x) = F_0(x)$ Residual berdistribusi normal

H_1 : $F(x) \neq F_0(x)$ Residual tidak berdistribusi normal

Daerah penolakan H_0 adalah jika $p\text{-value} < \alpha$ (nilai $\alpha = 0,05$)

Tabel 6 Uji Shapiro-Wilk

Model	P-value
SARIMA (1,1,1)(1,1,1) ¹²	4.206e-08
SARIMA (1,1,1)(0,1,1) ¹²	0.0001392
SARIMA (0,1,2)(1,1,0) ¹²	0.32

Berdasarkan tabel 6, setelah diuji didapatkan hanya nilai p -value model SARIMA SARIMA (0,1,2)(1,1,0)¹² $> \alpha$ (0,05) maka H0 diterima sehingga disimpulkan residual berdistribusi normal.

MAPE (Mean Absolute Percentage Error) menunjukkan rata-rata kesalahan dalam bentuk persentase terhadap data aktual. Nilai MAPE $< 10\%$ termasuk dalam kategori sangat baik untuk model prediksi. Hasil evaluasi model menggunakan MAPE diperoleh 5.32%, yang menunjukkan bahwa model ini layak digunakan untuk forecasting. Akurasi sebesar 94.67% menunjukan bahwa model prediksi mendekati kenyataan

3.3. Pemilihan Model Terbaik


Selanjutnya yaitu menentukan model yang paling baik dari model lain yang telah memenuhi asumsi *white noise* dan distribusi normal berdasarkan nilai *Akaike's Information Criterion* (AIC) terkecil dan *Mean Absolute Percentage Error* (MAPE) terkecil yang diperoleh suatu model.

Hasil yang diperoleh dari nilai AIC terkecil dan MAPE terkecil pada model SARIMA (0,1,2)(1,1,0)¹² yaitu AIC dengan nilai sebesar 802.87 dan nilai BIC sebesar 810.27. Berdasarkan estimasi dan uji signifikansi parameter sebelumnya (Tabel 7) diperoleh model SARIMA yaitu :

$$(1-0.0095647B)(1-0.4649728B^2)(1-0.6090992B^{12})(1-B)^1(1-B^{12})^1 Y_t = \varepsilon_t$$

Model SARIMA (0,1,2)(1,1,0)¹² layak digunakan untuk meramalkan data penjualan ritel mobil bekas untuk 12 bulan ke depan.

Selanjutnya dengan menggunakan model SARIMA terbaik yaitu SARIMA (0,1,2)(1,1,0)¹² akan dilakukan peramalan terhadap banyak penjualan ritel mobil bekas selama 12 bulan ke depan yaitu pada bulan Januari 2025 sampai dengan bulan Desember 2025.



Gambar 4 Grafik Data Hasil Peramalan

Berdasarkan Gambar 4 dapat dilihat bahwa hasil peramalan banyaknya penjualan ritel mobil bekas cenderung mengalami fluktuasi mengikuti pola musimannya.

Tabel 7 Hasil Peramalan

Periode	Hasil Peramalan
Januari 2024	10.440,33
Februari 2024	11.492,42
Maret 2024	14.333,13
April 2024	12.954,07
Mei 2024	12.849,43
Juni 2024	12.530,52
Juli 2024	12.064,31
Agustus 2024	13.047,49
September 2024	11.713,23
Oktober 2024	11.284,97
November 2024	10.209,43
Desember 2024	9.510,43

Berdasarkan Tabel 7 diperoleh hasil peramalan 12 periode ke depan dari Januari 2024 sampai Desember 2024. Penjualan ritel mobil bekas akan mencapai angka tertinggi pada bulan Maret 2024, yaitu sebanyak 14,333 juta dollar.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan dapat disimpulkan bahwa model terbaik untuk peramalan penjualan ritel mobil bekas dengan metode SARIMA adalah SARIMA (0,1,2)(1,1,0)¹² dengan akurasi MAPE sebesar 5,32%. Model SARIMA (0,1,2)(1,1,0)¹² mempunyai persamaan model sebagai berikut:

$$(1-0.0095647B)(1-0.4649728B^2)(1-0.6090992B^{12})(1-B)^1(1-B^{12})^1 Y_t = \varepsilon_t$$

Setelah diperoleh model terbaik, selanjutnya dilakukan peramalan selama 12 bulan ke depan yaitu pada bulan Januari 2025 sampai dengan bulan Desember 2025. Hasil peramalan menunjukkan penjualan ritel mobil bekas cenderung mengalami fluktuasi mengikuti pola musimannya. Berdasarkan hasil peramalan, penjualan tertinggi terjadi di bulan Maret sebanyak 14,333 juta dollar dan penjualan terendah di bulan Desember sebanyak 9,510 juta dollar. Untuk memastikan peningkatan penjualan, penting untuk memperhatikan tren yang dihasilkan oleh model serta mempertimbangkan faktor-faktor yang dapat mempengaruhi penjualan ritel mobil bekas, seperti faktor eksternal kondisi ekonomi, kebijakan pajak, inovasi produk, dan promosi. Penyesuaian model secara berkala penting untuk menjaga akurasi prediksi seiring perubahan pasar.

5. UCAPAN TERIMA KASIH

Terima kasih kepada Bapak Ihsan Fathoni Amri selaku dosen pendamping yang selalu memberikan arahan, semangat, dan motivasi sehingga proposal artikel ilmiah ini dapat terselesaikan dengan baik. Terima kasih juga kepada Bapak M. Al-Haris selaku dosen pembimbing yang telah memberikan usulan serta masukan sehingga peneliti dapat berkesempatan untuk melakukan penelitian ini. Terakhir, terima kasih juga kepada seluruh teman-teman Statistika yang telah membantu selama proses penelitian dan pembuatan proposal artikel ilmiah.

DAFTAR PUSTAKA

- [1] S. B. Chudo and G. Terdik, "Modeling and Forecasting Time-Series Data with Multiple Seasonal Periods Using Periodograms," *Econometrics*, vol. 13, no. 2, p. 14, 2025, doi: 10.3390/econometrics13020014.

-
- [2] J. Chen, "Time Series Analysis and Forecast of Sales of New Car and Used Car Using SARIMA Model," *Advances in Economics, Management and Political Sciences*, vol. 86, no. 1, pp. 122–132, 2024, doi: 10.54254/2754-1169/86/20240826.
- [3] L. Junaedi, N. Damastuti, and A. Widodo, "Penerapan Metode Seasonal ARIMA (SARIMA) untuk Peramalan Penjualan Barang dengan Pola Musiman Tahunan," *JISEM Jurnal Program Studi Informatika Universitas Katolik Widya Mandala Surabaya*, vol. 01, pp. 38–48, 2025, doi: 10.33508/jisem.v1i01.7403.
- [4] Nalini, "5 Common Mistakes to Avoid When Forecasting Demand in Manufacturing," Deskera Blog.
- [5] H. T. A. Simanjuntak, A. Lumbanraja, G. Samosir, and Regita, "Prediksi Single-Step dan Multi-Step Data Cuaca Menggunakan Model Long Short-Term Memory dan Sarima," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 12, no. 2, pp. 399–410, 2025, doi: 10.25126/jtiik.2025129444.
- [6] G. R. Estefania and A. Tripena, "Rainfall Forecasting Using Seasonal Autoregressive Integrated Moving Average Method And Decomposition Method in Pangkalan Bun," 2025.
- [7] N. M. Sunariadi *et al.*, "PREDIKSI PRODUKSI BAWANG MERAH DI KABUPATEN NGANJUK DENGAN METODE SEASONAL ARIMA (SARIMA)," *Jurnal Pendidikan Matematika dan Matematika*, vol. 6, no. 1, pp. 49–60, 2022, doi: 10.36526/tr.v%vi%i.1672.
- [8] L. Fernandes Tokan, A. Hermawan, F. Sains dan Teknologi, and U. Teknologi Yogyakarta, "Implementasi Model SARIMA Untuk Memprediksi Produksi Minyak Kelapa Sawit," 2023, [Online]. Available: <https://ditjenbun.pertanian.go.id/template/uploads/202>
- [9] M. I. Rizki and T. A. Taqiyyuddin, "Penerapan Model SARIMA untuk Memprediksi Tingkat Inflasi di Indonesia," *Jurnal Sains Matematika dan Statistika*, vol. 7, no. 2, Aug. 2021, doi: 10.24014/jsms.v7i2.13168.
- [10] F. Zundina Ulya, A. Rony Wijaya, and P. Laras Puspita, "Peramalan Harga Cabai dan Bawang di Pasar Tradisional Purwokerto dengan Model Autoregressive Integrated Moving Average (ARIMA) (Forecasting Chili and Onion Prices in Purwokerto Traditional Markets with the Autoregressive Integrated Moving Average (ARIMA))," 2023.
- [11] R. Mulyani, Y. Puspita Sari, P. Studi Budidaya Ikan, F. Perikanan dan Kelautan Universitas PGRI Palembang, P. Transportasi Sungai, and D. Dan Penyeberangan Palembang, "Forecasting Produksi Perikanan Budidaya Di Kota Palembang Dengan Metode Autoregressive Integrated Moving Average (ARIMA)," *Jurnal Ilmiah Matematika dan Ilmu Pengetahuan Alam*, vol. 16, no. 1, 2022, doi: 10.31851/sainmatika.v16i1.xxxx.
- [12] M. S. Buntara, H. Napitupulu, and N. Gusriani, "Pemrograman Python Untuk Peramalan Data Deret Waktu Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (Sarima)," 2023.