

Application of the Seasonal Autoregressive Integrated Moving Average (SARIMA) Method to Forecast the Number of Vessel Passenger Departures at Yos Soedarso Ambon Port

Winda Butarbutar¹, Marlon S. Noya Van Delsen², Ronald J. Djami^{3*}

¹²³Universitas Pattimura

Jl. Ir. M. Putuhena, Kampus Unpatti Poka, Ambon, 97233, Maluku, Indonesia

Email: corresponding_author ronalddjami@gmail.com

Manuscript submitted : Will be filled by editors;

Accepted for publication : Will be filled by editors.

doi : <https://doi.org/10.30598/tensorvol4iss2pp105-118>

Abstract: Maluku Province is a fairly large archipelago in Indonesia. The large number of islands which are the administrative areas of Maluku Province, encourages the creation of a supporting transportation system. Yos Soedarso Ambon Port is the largest port in Ambon. Based on the statistics of Indonesia, the number of ship passengers at Yos Soedarso Port in Ambon during the April 2023 period experienced an increase of 44.97 percent, while in the March 2023 period, it only experienced an increase of 42.94 percent. Because the data used is time series data and has a seasonal pattern, the most appropriate method for predicting the number of passengers is the Seasonal Autoregressive Moving Average (SARIMA) method. The SARIMA method is an approach model developed from the Autoregressive Moving Average (ARIMA) model used on time series or data with a seasonal pattern. This research produced the best model for forecasting the number of departures of ship passengers at Yos Soedarso Port, Ambon. With an MSE value of 26.44. with the shape of the model with MAPE 10.23%.

Keywords: MAPE, MSE, Passengers, Port, SARIMA, Time series

1. Pendahuluan

Indonesia merupakan negara maritim ataupun kepulauan (*archipelagic state*) terbesar di dunia yang memiliki luas wilayah perairan sebesar 3,25 juta km² atau sekitar 63 persen dari total wilayah Indonesia [1]. Sebagai negara maritim, laut memiliki peran penting dalam kehidupan masyarakat Indonesia, baik sebagai sumber kehidupan, sumber daya alam dan juga sebagai jalur transportasi salah satunya di Provinsi Maluku [2].

Provinsi Maluku merupakan wilayah kepulauan yang cukup luas di Indonesia. Banyaknya pulau yang menjadi wilayah administrasi Provinsi Maluku, mendorong harus terciptanya sistem transportasi yang mampu menjamin keberlangsungan mobilitas masyarakat agar lebih efektif dan efisien. Pelabuhan-pelabuhan di Provinsi Maluku sebagian besar melayani pelayaran dalam negeri dengan skala kecil dan menengah, hanya beberapa pelabuhan saja yang mampu melayani pelayaran luar negeri dan skala yang cukup besar. Seiring dengan dengan meningkatnya permintaan transportasi kapal pada pelabuhan-pelabuhan menyebabkan terjadinya perkembangan sarana dan alat transportasi dari waktu ke waktu [3].

Meningkatnya jumlah wisatawan dan juga penduduk lokal, sehingga jumlah Pelabuhan dan kapal penumpang yang beroperasi di Maluku semakin banyak, modern, nyaman, serta mampu mengakomodasikan lebih banyak penumpang, hal ini tentu berdampak positif pada sektor wisata di Maluku dan juga berkontribusi pada pertumbuhan ekonomi daerah, salah satunya pada Pelabuhan Yos Soedarso Ambon, yang merupakan Pelabuhan terbesar di Ambon dan dikenal sebagai pusat distribusi barang di wilayah timur Indonesia karena memiliki posisi yang strategis.

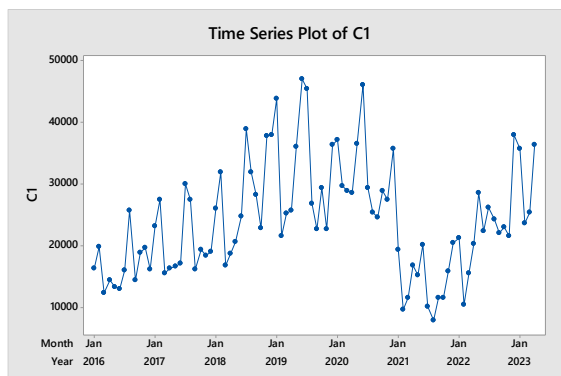
Badan Pusat Statistik (BPS) mencatat jumlah penumpang kapal laut di Pelabuhan Yos Soedarso Ambon selama periode April 2023 mengalami peningkatan sebesar 44,97 persen sementara pada periode Maret 2023 yang hanya mengalami peningkatan sebesar 42,94 persen. Hal itu disebabkan karena banyaknya masyarakat yang ingin melakukan mudik menjelang Hari Raya Idul Fitri.

Pada umumnya data penumpang merupakan data time series atau runtun waktu, yang apabila berdasarkan uraian latar belakang data penumpang memiliki pola musiman, dimana akan ada lonjakan jumlah penumpang pada waktu-waktu tertentu. Untuk mengetahui kondisi jumlah penumpang maka dibutuhkan suatu metode penelitian yang dapat digunakan untuk meramalkan jumlah penumpang tersebut dengan tingkat kepercayaan yang tepat. Dimana penelitian yang telah dilakukan diantaranya [4] yakni Peramalan Jumlah Penumpang dari Pelayaran Dalam Negeri di Pelabuhan Kota Makassar Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA) dimana di dapatkan model terbaik untuk prediksi jumlah penumpang turun dipelabuhan Kota Makassar yaitu SARIMA (0,1,1)(1,1,0)₁₂ yang menghasilkan peramalan bahwa jumlah penumpang pada tahun 2015 dan 2016 meningkat pada bulan Juli. Karena data yang digunakan merupakan data time series dan memiliki pola musiman sehingga metode yang paling tepat untuk meramalkan jumlah penumpang merupakan metode Seasonal Autoregressive Moving Average (SARIMA). Metode SARIMA merupakan suatu model pendekatan yang dikembangkan dari model Autoregressive Moving Average (ARIMA) yang digunakan pada data time series atau data runtun waktu yang berpola musiman. Berdasarkan beberapa Penelitian terdahulu yang menggunakan metode SARIMA menghasilkan nilai peramalan yang akurat, sehingga peneliti tertarik untuk membuat penelitian sejenis terkait Penerapan Metode Seasonal Autoregressive Moving Average (SARIMA) Untuk Peramalan jumlah keberangkatan penumpang kapal di Pelabuhan Yos Soedarso Ambon

2. METODOLOGI

2.1. Data Penelitian

Pada penelitian ini data yang digunakan adalah data sekunder yang diperoleh dari publikasi Badan Pusat Statistik Kota Ambon berupa data bulanan jumlah penumpang kapal yang berangkat pada Pelabuhan Yos Soedarso Ambon pada periode Januari 2016 sampai Desember 2022. Berikut merupakan Grafik data yang digunakan pada penelitian ini:



Gambar 1. Plot data jumlah penumpang kapal yang berangkat tahun 2016-2022

2.2. Tahapan Penelitian

Tahapan dalam penelitian ini dijelaskan sebagai berikut:

Menginput data bulanan jumlah keberangkatan penumpang kapal di Pelabuhan Yos Soedarso Ambon pada periode Januari 2016 - Desember 2022.

Menampilkan plot data dari jumlah penumpang kapal yang berangkat pada Pelabuhan Yos Soedarso.

Mengidentifikasi stasioneritas data terhadap varians dan mean.

- Melakukan transformasi Box-Cox pada data yang belum stasioner dalam varians.
- Melakukan differencing non-musiman pada data yang belum stasioner terhadap mean non-musiman.
- Melakukan differencing musiman pada data yang belum stasioner terhadap mean musiman.

Melakukan estimasi parameter model

Melakukan uji diagnostik model:

- Melakukan uji asumsi residual White Noise dengan Ljung Box-Pierce
- Melakukan uji residual berdistribusi normal dengan Kormogorov-Smirnov.

Memilih model terbaik berdasarkan nilai MSE.

Melakukan peramalan menggunakan model terbaik yang diperoleh.

Interpretasi hasil yang didapatkan.

3. HASIL DAN PEMBAHASAN

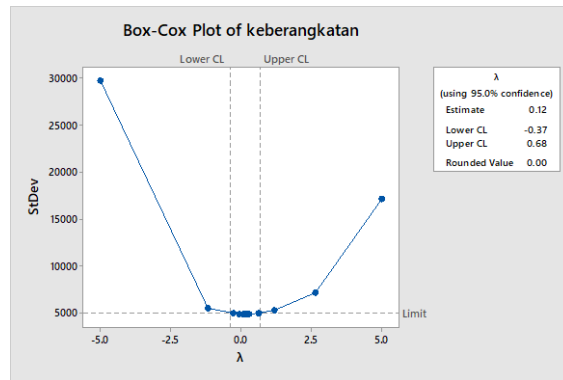
3.1. Analisis Deskriptif

Analisis deskriptif dilakukan untuk memberikan gambaran umum terjadi peningkatan dan penurunan pada bulan-bulan tertentu, oleh sebab itu data jumlah penumpang kapal memiliki faktor musiman. Terjadinya peningkatan jumlah penumpang kapal setiap tahunnya memiliki pola yang sama setiap tahunnya dan juga mengalami kenaikan. Trend naik pada data tersebut menandakan jumlah penumpang yang meningkat setiap tahunnya walaupun sempat terjadi penurunan dalam beberapa tahun yaitu pada tahun 2021 dan 2022. Sehingga diduga bahwa data jumlah penumpang kapal yang berangkat pada Pelabuhan Yos Soedarso Ambon memiliki pola musiman dan pola trend yang cenderung naik sehingga perlu dilakukan uji stasioneritas data terhadap varians dan mean.

3.2. Identifikasi Model SARIMA

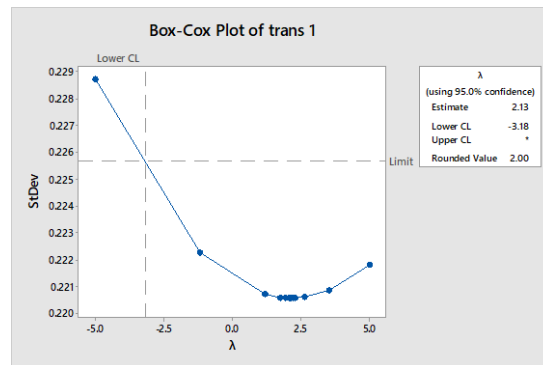
3.2.1. Uji Stasioneritas Data

Uji stasioneritas yang pertama dilakukan adalah uji stasioneritas terhadap varians yang di uji menggunakan transformasi Box-Cox. Data dikatakan stasioner terhadap varians apabila memiliki nilai rounded value (λ) sama dengan 1 [5].




Gambar 2. Plot Box-cox

Transformasi Box-Cox pada Gambar 2 menunjukkan bahwa besar lambda optimal yaitu $\lambda < 1$ yang berarti data jumlah penumpang kapal tidak stasioner terhadap varians sehingga perlu dilakukan proses transformasi Box-Cox, kemudian akan dilakukan kembali transformasi Box-Cox seperti pada gambar 3 berikut [6].



Gambar 3. Plot transformasi Box-cox pertama


Berdasarkan Gambar 3 dapat dilihat bahwa setelah dilakukan proses transformasi pertama nilai lambda optimal yaitu $\lambda > 1$ sehingga data belum stasioner terhadap varians, sehingga perlu dilakukan transformasi Box-Cox kedua seperti pada gambar 4 berikut [6].



Gambar 4. Plot transformasi Box-Cox kedua

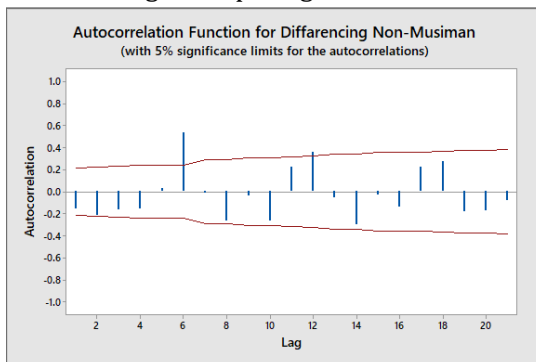
Setelah dilakukan proses transformasi Box-Cox kedua, terlihat pada Gambar 4.4 menunjukkan bahwa nilai $\lambda = 1$ sehingga dapat dikatakan bahwa data sudah stasioner terhadap varians.

Selanjutnya dapat dilakukan identifikasi model sekaligus melakukan pengecekan data apakah sudah stasioner dalam rata-rata (mean) dengan menggunakan plot ACF (Autocorrelation function) pada Gambar 5 berikut.



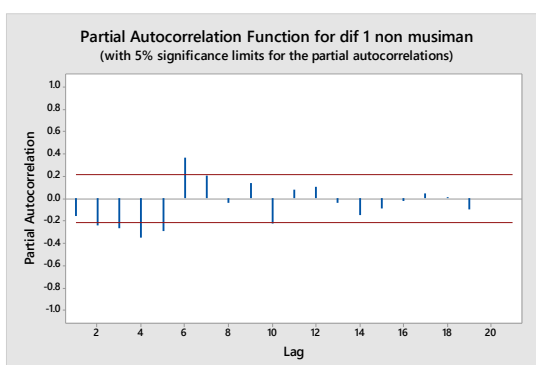
Gambar 5. Plot ACF data transformasi

Gambar 5 menunjukkan bahwa nilai ACF pada 5 lag pertama keluar dari selang kepercayaan hal ini menunjukkan jika data belum stasioner terhadap rata-rata (mean), sehingga perlu dilakukan differencing non-musiman agar data stasioner terhadap rata-rata [7]. Kemudian akan dibuat plot ACF differencing pertama pada Gambar 6 yaitu mulai dari lag 1 sampai lag 21.



Gambar 6. Plot ACF data *differencing* non-musiman


Selanjutnya yaitu plot PACF non musiman yang akan ditunjukkan pada Gambar 7 berikut:



Gambar 7. Plot PACF non-musiman

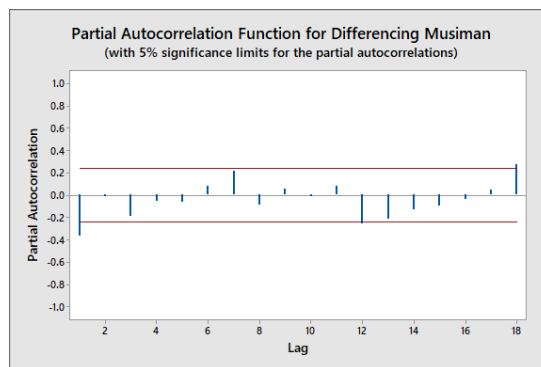
Dari Gambar 6 terlihat bahwa 3 lag pertama tidak keluar dari garis selang kepercayaan. Hal ini menunjukkan jika data telah stasioner terhadap mean. Sedangkan dari Gambar 7 menunjukkan bahwa pada lag 2, 3, 4, dan 5 keluar dari garis selang kepercayaan. Namun, lag musiman plot ACF pada lag ke-6 dan lag ke-12 tidak mengalami penurunan secara eksponensial dan pada lag musiman PACF terdapat pada lag 6 sehingga diperlukan dilakukan proses differencing musiman.

Proses differencing musiman dilakukan dengan melakukan penggeseran data sebanyak 6 periode dan 12 periode kebelakang dengan menerapkan persamaan (II.2) dan hasilnya dapat dilihat pada Lampiran 5. Selanjutnya nilai ACF yang telah di differencing musiman tersebut dibuat plot dari lag 1 sampai lag 19 seperti Gambar 8 berikut.



Gambar 8. Plot ACF data differencing musiman

Langkah selanjutnya adalah menghitung nilai PACF menggunakan persamaan nilai koefisien ACF differencing musiman berdasarkan persamaan (II.13) untuk menentukan nilai koefisien setiap lag [8]. Hasil perhitungan nilai koefisien selengkapnya dapat dilihat pada Lampiran 6. Nilai koefisien PACF tersebut kemudian dibuat plot pada Gambar 9 mulai dari lag 1 sampai dengan lag 18 sebagai berikut:



Gambar 9. Plot PACF.

Gambar 8 menunjukkan plot ACF bahwa lag 1 memotong batas signifikan dengan nilai lag sebesar -0.368477 dan diikuti oleh lag yang mengalami penurunan secara eksponensial mendekati nol, sehingga dapat diidentifikasi model MA(1) untuk pola non-musiman [9]. Sedangkan untuk lag musimannya tidak terjadi penurunan secara eksponensial sehingga dapat diidentifikasi tidak memiliki model musiman (SMA). Gambar 9 menunjukkan plot PACF lag 1 memotong batas signifikan dengan nilai lag sebesar -0.368477 dan diikuti oleh lag yang mengalami penurunan secara eksponensial mendekati nol sehingga dapat diidentifikasi bahwa memiliki model AR(1) untuk pola non musiman. Sedangkan untuk lag musimannya berdasarkan Gambar 9 memotong batas atas signifikansi pada lag 18, sehingga dapat diidentifikasi memiliki model musiman SAR (1) Sehingga di dapatkan model pendugaan sementara yaitu SARIMA (0,1,1)(1,1,1)⁶[10].

3.2.2. Uji Signifikansi Parameter Model Sementara

Setelah melakukan penduggan model sementara, Langkah selanjutnya adalah melakukan uji signifikansi pada parameter model yang sesuai [11]. Model dikatakan memenuhi kriteria apabila nilai *p* – value harus lebih kecil dari taraf signifikan. Taraf signifikan yang digunakan yakni 5% ($\alpha = 0.05$) dengan hipotesis sebagai berikut:

H_0 : estimasi parameternya = 0 (parameter tidak signifikan dalam model)

H_1 : estimasi parameternya \neq 0 (parameter signifikan dalam model)

Statistik Uji: uji t

$$t_{hitung} = \frac{\text{estimasi parameter } (\phi_1)}{\text{standart error parameter}}$$

Kriteria pengujian : Tolak H_0 jika $|t_{hitung}| > t_{(\frac{\alpha}{2}, df)}$

dengan ringkasan hasil pengujian dituliskan pada Tabel 1. berikut.

Tabel 1. Uji signifikansi parameter model sementara (sumber: minitab17)

MODEL	Parameter	Koefisien	SE Koefisien	T - value	P - value	ket
<i>SARIMA</i> (1,1,1)(1,1,1) ⁶	AR (1)	0.1636	0.2350	0.70	0.498	T.Signifikan
	SAR(6)	0.3640	0.2251	1.62	0.110	T.Signifikan
	MA(1)	0.6295	0.1824	3.45	0.001	Signifikan
	SMA(6)	0.8019	0.1548	5.18	0.000	Signifikan
<i>SARIMA</i> (1,1,0)(1,1,1) ⁶	AR(1)	-0.3525	0.1167	-3.02	0.003	Signifikan
	SAR(6)	0.1778	0.2673	0.67	0.508	T.Signifikan
	SMA(6)	0.6260	0.2027	3.09	0.003	Signifikan
<i>SARIMA</i> (0,1,1)(1,1,1) ⁶	SAR(6)	0.3629	0.2180	1.66	0.100	T.Signifikan
	MA(1)	0.5144	0.1014	5.08	0.000	Signifikan
	SMA(6)	0.7995	0.1482	5.39	0.000	Signifikan
<i>SARIMA</i> (0,1,1)(0,1,1) ⁶ *	MA(1)	0.4840	0.1021	4.74	0.000	Signifikan
	SMA(6)	0.5048	0.1055	4.78	0.000	Signifikan
<i>SARIMA</i> (1,1,0)(0,1,1) ⁶ *	AR(1)	-0.3584	0.1122	-3.19	0.002	Signifikan
	SMA(6)	0.4863	0.1070	4.54	0.000	Signifikan
<i>SARIMA</i> (1,1,1)(0,1,1) ⁶	AR(6)	0.1296	0.2443	0.53	0.597	T.Signifikan
	MA(1)	0.5772	0.1996	2.89	0.005	Signifikan
	SMA(6)	0.5158	0.1058	4.88	0.000	Signifikan
<i>SARIMA</i> (1,1,1)(1,1,0) ⁶	AR(1)	0.0736	0.2599	0.28	0.778	T.Signifikan
	SAR(6)	-0.3250	0.1262	-2.57	0.012	Signifikan
	MA(6)	0.5294	0.2187	2.42	0.018	Signifikan
<i>SARIMA</i> (0,1,1)(1,1,0) ⁶ *	SAR(6)	-0.3272	0.1234	-2.65	0.010	Signifikan
	MA(1)	0.4722	0.1027	4.60	0.000	Signifikan

*: Model yang signifikan

Tabel 1 tersebut diperoleh 8 model dugaan sementara, 3 memiliki parameter yang signifikan sedangkan 5 model tidak signifikan. Model-model pendugaan sementara yang signifikan dianggap sesuai untuk data jumlah keberangkatan penumpang kapal pada Pelabuhan Yos Soedarso Ambon. Selanjutnya akan dilakukan uji residual model dugaan sementara untuk menentukan model terbaik.

3.3. Uji Diagnostik Model

Uji diagnostik model dilakukan dengan memeriksa residual model dugaan sementara yang memiliki parameter signifikan. adapun parameter dugaan sementara yang signifikan yakni *SARIMA* (0,1,1)(0,1,1)⁶, *SARIMA* (1,1,1)(0,1,1)⁶ dan *SARIMA* (0,1,1)(1,1,1)⁶. Selanjutnya pada model dugaan sementara yang

memiliki parameter signifikan dilakukan pengujian yang meliputi uji White Noise dan uji distribusi normal Kolmogorov-Smirnov.

3.3.1 Uji Asumsi Residual *White Noise*

Uji Asumsi white noise dilakukan pada model dugaan sementara yang memenuhi kriteria signifikan menggunakan Q Box-Pierce [12]. Tahap uji white noise pada model dugaan sementara adalah sebagai berikut:

1. Model *SARIMA* (0,1,1)(0,1,1)⁶

Uji Q Box-Pierce pada model *SARIMA* (0,1,1)(0,1,1)⁶ menggunakan Persamaan (II.31) dengan hipotesis sebagai berikut [13]:

H_0 : Residual memenuhi asumsi residual

H_1 : Residual tidak memenuhi asumsi residual

$$Q = n(n + 2) \sum_{k=1}^k \frac{\hat{\rho}_k^2}{(n - k)}, n > k$$

Daerah penolakan : Tolak H_0 apabila $p - value < \alpha$ atau $Q > x^2_{\alpha,df}$

Hasil uji white noise yang di dapatkan menggunakan bantuan software minitab 17 dapat dilihat pada Lampiran 15, Adapun hasil dibuat pada Tabel 4.3 berikut.

Tabel 2. Uji Q Box-Pierce *SARIMA* [(0,1,1)(0,1,1)]⁶ (sumber: minitab 17)

lag	DF	$x^2_{\alpha,df}$	Q	p-value
12	9	16,92	8,1	0,521
24	21	32,67	22,6	0,368
36	33	47,40	32,4	0,499
48	45	61,66	48,7	0,325

1. Berdasarkan Tabel 2 dapat diketahui jika nilai p-value lebih besar daripada nilai α dan nilai chi-square (Q) hitung lebih kecil daripada chi-square tabel. Sehingga dapat dikatakan bahwa model *ARIMA* (0,1,1)(0,1,1)⁶ terima H_0 yang berarti model *ARIMA* (0,1,1)(0,1,1)⁶ memenuhi uji asumsi white noiseengan nilai MSE sebesar 26.44 yang dapat dilihat pada lampiran 10.

2. Model *SARIMA* (1,1,1)(0,1,1)⁶

Uji Q Box-Pierce pada model *SARIMA* (1,1,1)(0,1,1)⁶ menggunakan Persamaan (II.31) dengan hipotesis sebagai berikut:

H_0 : Residual memenuhi asumsi residual

H_1 : Residual tidak memenuhi asumsi residual

$$Q = n(n + 2) \sum_{k=1}^k \frac{\hat{\rho}_k^2}{(n - k)}, n > k$$

Daerah penolakan : Tolak H_0 apabila $p - value < \alpha$ atau $Q > x^2_{\alpha,df}$

Hasil uji white noise yang di dapatkan menggunakan bantuan software minitab 17 dapat dilihat pada Lampiran 16, Adapun hasil dibuat pada Tabel 4.4 berikut.

Tabel 3. Uji Q Box-Pierce SARIMA (1,1,0)(0,1,1)⁶ (sumber: minitab 17)

lag	DF	$x^2_{\alpha,df}$	Q	p-value
12	9	16,92	11,4	0,252
24	21	32,67	25,6	0,221
36	33	47,40	37,1	0,287
48	45	61,66	54,4	0,159

Berdasarkan Tabel 3 dapat diketahui nilai p-value lebih besar daripada nilai α dan nilai chi-square (Q) hitung lebih kecil daripada chi-square tabel. Sehingga dapat dikatakan bahwa model SARIMA (1,1,1)(0,1,1)⁶ terima H_0 yang berarti model SARIMA (1,1,1)(0,1,1)⁶ memenuhi uji asumsi white noise dengan nilai MSE sebesar 27.80 yang dapat dilihat pada lampiran 11.

3. Model SARIMA (0,1,1)(1,1,1)⁶

Uji Q Box-Pierce pada model SARIMA (0,1,1)(1,1,1)⁶ menggunakan Persamaan (II.44) dengan hipotesis sebagai berikut:

H_0 : Residual memenuhi asumsi residual

H_1 : Residual tidak memenuhi asumsi residual

$$Q = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n - k)}, n > k$$

Daerah penolakan : Tolak H_0 apabila $p - value < \alpha$ atau $Q > x^2_{\alpha,df}$

Hasil uji white noise yang di dapatkan menggunakan bantuan software minitab 17 dapat dilihat pada Lampiran 17, Adapun hasil dibuat pada Tabel 4.5 berikut.

Tabel 4. Uji Q Box-Pierce SARIMA [(0,1,1)(1,1,0)]⁶ (sumber: minitab 17)

lag	DF	$x^2_{\alpha,df}$	Q	p-value
12	9	16,92	12,2	0,203
24	21	32,67	23,6	0,314
36	33	47,40	34,2	0,408
48	45	61,66	52,9	0,194

Berdasarkan Tabel 4 dapat diketahui nilai p-value lebih besar daripada nilai α dan nilai chi-square (Q) hitung lebih kecil daripada chi-square tabel. Sehingga dapat dikatakan bahwa model SARIMA (0,1,1)(1,1,1)⁶ terima H_0 yang berarti model SARIMA (0,1,1)(1,1,1)⁶ memenuhi uji asumsi white noise dengan nilai MSE sebesar 28.20 yang dapat dilihat pada lampiran 14.

3.3.2 Uji Distribusi Normal

Uji distribusi normal dilakukan pada residual model dugaan sementara yang telah memenuhi uji asumsi residual white noise yaitu yakni SARIMA (0,1,1)(0,1,1)⁶, SARIMA (1,1,1)(0,1,1)⁶ dan SARIMA (0,1,1)(1,1,1)⁶. dengan menggunakan uji Kormogorov-Smirnov. Adapun tahapan dalam melakukan uji residual berdistribusi normal menggunakan Persamaan (II.30) dengan hipotesis sebagai berikut [14]:

Hipotesis :

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Statistik Uji


$$KS = \text{Max}[FT - FS]$$

Kriteria Pengujian : Jika $p - \text{value} > \alpha$ maka terima H_0

1. Model SARIMA (0,1,1)(0,1,1)⁶

Tabel 5. Uji distribusi normal SARIMA [(0,1,1)(0,1,1)]⁶ (sumber: minitab 17)

Mean	stDev	n	D	p-value
0,04262	5,073	77	0,079	0,150



Gambar 10. Grafik distribusi normal


Grafik pada Gambar 10 menunjukkan jika distribusi residual model mengikuti garis normal, sehingga residual model telah memenuhi asumsi distribusi normal.

2. Model SARIMA (1,1,0)(0,1,1)⁶

Tabel 6. Uji distribusi normal SARIMA [(1,1,0)(0,1,1)]⁶ (sumber: minitab 17)

Mean	stDev	n	D	p-value
0,03749	5,203	77	0,070	0,150

Berdasarkan Tabel 6 dapat diketahui bahwa residual model SARIMA (1,1,0)(0,1,1)⁶ berdistribusi normal karena nilai $p - \text{value} > \alpha$ yaitu $0.150 > 0.05$ sehingga H_0 diterima. Berikut merupakan grafik model SARIMA (1,1,0)(0,1,1)⁶.



Gambar 11. Grafik distribusi normal model SARIMA (1,1,0)(0,1,1)⁶


Grafik pada Gambar 11 menunjukkan jika distribusi residual model mengikuti garis normal, sehingga residual model telah memenuhi asumsi distribusi normal.

3. Model SARIMA (0,1,1)(1,1,0)⁶

Tabel 7. Uji distribusi normal SARIMA [(0,1,1)(1,1,0)]⁶ (sumber: minitab 17)

Mean	stDev	n	D	p-value
0,04033	5,240	77	0,080	0,150

Berdasarkan Tabel 7 dapat diketahui bahwa residual model SARIMA (0,1,1)(1,1,1)⁶ berdistribusi normal karena nilai $p - value > \alpha$ yaitu $0.150 > 0.05$ sehingga H_0 diterima. Berikut merupakan grafik model SARIMA (0,1,1)(1,1,1)⁶.



Gambar 12. Grafik distribusi normal model SARIMA (0,1,1)(1,1,0)⁶

Grafik pada Gambar 12 menunjukkan jika distribusi residual model mengikuti garis normal, sehingga residual model telah memenuhi asumsi distribusi normal.

3.4. Pemilihan Model Terbaik

Pemilihan model terbaik dilakukan apabila terdapat lebih dari satu model yang memenuhi uji asumsi diagnostik [15]. Model yang telah memenuhi asumsi uji diagnostik terdapat tiga model sehingga untuk memilih model terbaik dilihat berdasarkan nilai MSE terkecil. Berdasarkan nilai MSE di dapatkan bahwa model SARIMA (0,1,1)(0,1,1)⁶ merupakan model terbaik yang layak digunakan dengan nilai. $MSE = 26.44$

3.5. Peramalan SARIMA

Berdasarkan model terbaik yang didapatkan, selanjutnya adalah mengembangkan dari model tersebut untuk mempermudah proses peramalan. Pengembangan model SARIMA (0,1,1)(0,1,1)⁶ dilakukan berdasarkan Persamaan (II.29), dengan orde non-musiman AR(0), orde non-musiman MA(1), orde musiman SAR(0), dan orde musiman SMA (1). Proses differencing stasioner data terhadap mean musiman dilakukan satu kali sedangkan untuk differencing stasioner data terhadap mean non-musiman satu kali, sehingga orde $d(1)$ dan $D(1)$.

Bentuk akhir persamaan diperoleh dengan menerapkan backshift operator untuk mencari hasil ramalan pada periode $ke - t$ pada jangka waktu musiman 6.

$$\hat{Z}_t = \hat{e}_{t-6} + 0,4840e_{t-1} + 0,5048e_{t-6} + e_t$$

Persamaan ini merupakan bentuk setelah melalui proses backshift operator dari Persamaan (II.29) dengan nilai koefisien AR(0), SAR(0), SMA (6), dan MA(1) yang didapatkan dari Tabel 1. Karena untuk mencapai data yang stasioner melibatkan proses transformasi, maka data perlu dikembalikan ke bentuk semula.

Maka persamaan model SARIMA yang dapat digunakan untuk melakukan peramalan pada periode selanjutnya adalah sebagai berikut:

$$Z_t = \exp \left(\sqrt{e_{t-6} + 0,4840e_{t-1} + 0,5048e_{t-6} + e_t} \right)$$

Persamaan model SARIMA setelah dilakukan transformasi kemudian dapat digunakan untuk meramalkan jumlah keberangkatan penumpang kapal di Pelabuhan Yos Soedarso Ambon. Hasil peramalan jumlah

keberangkatan penumpang kapal di Pelabuhan Yos Soedarso Ambon untuk 4 periode selanjutnya pada Januari sampai April 2023 ditunjukkan pada Tabel 8 berikut.

Tabel 8. Hasil Peramalan Periode Januari 2023-April 2023 (data transformasi).

Bulan	Hasil Peramalan 2023
Januari	106.6247
Februari	100.7763
Maret	102.7308
April	105.0197


Karena ini merupakan hasil peramalan dari data transformasi yang dilakukan sebanyak 2 kali, maka perlu dilakukan transformasi balik

Berdasarkan Tabel 8 hasil peramalan dari data transformasi yang telah di dapatkan dan telah diubah kembali, maka selanjutnya hasil peramalan akan disajikan dalam Tabel 9 berikut:

Tabel 9. Hasil Peramalan Periode Januari 2023-April 2023

Bulan	Hasil Peramalan 2023
Januari	30513
Februari	22896
Maret	25226
April	28224

Adapun hasil peramalan diatas dapat disajikan dalam bentuk grafik seperti berikut.



Gambar 13. Grafik hasil peramalan

Gambar 13 dan Tabel 9 menunjukkan jika jumlah keberangkatan penumpang kapal di Pelabuhan Yos Soedarso Ambon mengalami peningkatan pada awal periode yaitu bulan Januari sebanyak 30.513 dan penurunan pada periode Februari dimana jumlah penumpang sebanyak 22.896 penumpang. Namun, setelah itu mengalami peningkatan pada Maret dan April yaitu sebanyak 25.226 dan 28.224 penumpang. Setelah bulan-bulan tersebut jumlah keberangkatan penumpang kapal pada Pelabuhan Yos Soedarso Ambon mengalami penurunan dan juga peningkatan secara perlahan. Hal ini menunjukkan jika model $SARIMA(0,1,1)(0,1,1)^6$ adalah model yang sesuai untuk meramalkan jumlah keberangkatan penumpang kapal di Pelabuhan Yos Soedarso Ambon.

3.6. Ukuran Ketelitian Peramalan

Tabel 10. perhitungan nilai MAPE

Data aktual	Peramalan	$\frac{ A_t - F_t }{A_t}$
35658	30513	0.144
23650	22896	0.032
25452	25226	0.009
36380	28224	0.224
Jumlah	0.40923	

$$\begin{aligned}
 MAPE &= \frac{100 \times \sum_{t=1}^n \frac{|A_t - F_t|}{A_t}}{n} \\
 &= \frac{100 \times 0.40923}{4} \\
 &= \frac{40.923}{4} \\
 &= 10.23
 \end{aligned}$$

Berdasarkan Tabel 10 dapat dilihat bahwa hasil peramalan dengan menggunakan metode SARIMA mampu mengikuti data aktual. Dan untuk pengujian nilai akurasi dengan menggunakan nilai MAPE didapatkan hasil sebesar 10.23%. Berdasarkan kriteria MAPE diketahui bahwa apabila nilai MAPE di antara 10% – 20% maka dapat disimpulkan hasil peramalan tersebut memiliki nilai keakuratan baik [15].

4. KESIMPULAN

Berdasarkan pembahasan yang telah diuraikan pada penelitian ini, didapatkan bahwa model SARIMA terbaik untuk melakukan peramalan jumlah keberangkatan penumpang kapal di Pelabuhan Yos Soedarso Ambon yaitu model SARIMA (0,1,1)(0,1,1)⁶ dengan nilai MSE sebesar 26.44.

Dari penelitian ini dapat disimpulkan bahwa hasil peramalan jumlah keberangkatan penumpang kapal di Pelabuhan Yos Soedarso Ambon pada periode Januari 2023 sampai dengan April 2023 mengalami peningkatan pada awal periode yaitu bulan Januari sebanyak 30.513 dan penurunan pada periode Februari dengan jumlah penumpang sebanyak 22.896 penumpang. Kemudian mengalami peningkatan pada bulan Maret dan April 2023 sebanyak 25.226 dan 28.224 penumpang.

References

- [1] M. Kadarisman. (2017). Kebijakan keselamatan dan keamanan maritim dalam menunjang sistem transportasi laut. *J. Manaj. Transp. Logistik*, vol. 4, no. 2, pp. 177–192.
- [2] D. I. Purnama and O. P. Hendarsin. (2020). Peramalan Jumlah Penumpang Berangkat Melalui Transportasi Udara di Sulawesi Tengah Menggunakan Support Vector Regression (SVR). *Jambura J. Math.*, vol. 2, no. 2, pp. 49–59.
- [3] S. Putri. (2022). Peralaman Jumlah Keberangkatan Penumpang Pelayaran dalam Negeri Di Pelabuhan Tanjung Perak menggunakan Metode ARIMA dan SARIMA. *MATHunesa J. Ilmiah Matematika*, vol. 10, no. 01.
- [4] W. Y. M. Nasir. (2015). Peramalan Jumlah Penumpang Dari Pelayaran Dalam Negeri Di Pelabuhan Kota Makassar Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA). *Univ. Islam Negeri Alaudin Makassar*.
- [5] G. E. P. Box and D. R. Cox. (1964). An analysis of transformations. *J. R. Stat. Soc. Ser. B*, vol. 26, no. 2, pp.

211–243.

- [6] W. W. S. Wei. (2006). *Time Series Analysis: Univariate and Multivariate Methods*.
- [7] K. Mendome, N. Nainggolan, and J. Kekenusa. (2016). Penerapan Model Arima Dalam Memprediksi Jumlah Tindak Kriminalitas Di Wilayah Polresta Manado Provinsi Sulawesi Utara, *J. Mipa*, vol. 5, no. 2, pp. 113–116.
- [8] A. M. Tiro, S. Sukarna, and A. Aswi. (2006). Analisis Faktor. Andira Publisher Makasar.
- [9] S. Aziz, A. Sayuti, and M. Mustakim. (2017). Penerapan Metode ARIMA untuk Peramalan Pengunjung Perpustakaan UIN Suska Riau. in *Seminar Nasional Teknologi Informasi Komunikasi dan Industri*. pp. 186–193.
- [10] R. Rahmadayanti, B. Susilo, and D. Puspitaningrum. (2015). Perbandingan Keakuratan Metode Autoregressive Integrated Moving Average (ARIMA) dan Exponential Smoothing pada Peramalan Penjualan Semen di PT. Sinar Abadi,” *Rekursif J. Inform.*, vol. 3, no. 1.
- [11] H. Hartati. (2017). Penggunaan Metode Arima Dalam Meramal Pergerakan Inflasi. *J. Mat. Sains Dan Teknol.*, vol. 18, no. 1, pp. 1–10.
- [12] D. N. Nachrowi and H. Usman. (2006). *Ekonometrika: Pendekatan Populer dan Praktis Untuk Analisis Ekonomi dan Keuangan*.
- [13] S. Makridakis, S. C. Wheelwright, and V. E. McGee. (1999). *Metode dan aplikasi peramalan*.
- [14] R. Fahrudin. (2019). Peramalan Inflasi Dengan Metode Hybrid Sarima-Single Exponential Smoothing Untuk Penentuan Kebutuhan Hidup Layak Minimum (Kapita/Bulan): Kota Bandung.” Universitas Komputer Indonesia.
- [15] H. D. E. Sinaga and N. Irawati. (2018). Perbandingan Double Moving Average dengan Double Exponential Smoothing Pada Peramalan Bahan Medis Habis Pakai. *J. Teknol. dan Sist. Inf.*, vol. Vol. IV, no. 2, pp. 197–204.