



Forecasting Fuel Consumption Kapal X Menggunakan Metode Sarima Di Penajam Supply Base (PSB) Pertamina Hulu Kalimantan Timur

Wahyu Ardana¹✉, Irma Andrianti¹

⁽¹⁾Program Studi S1 Teknik Industri, Sekolah Tinggi Teknologi Migas, Balikpapan

DOI: [10.31004/jutin.v8i4.38468](https://doi.org/10.31004/jutin.v8i4.38468)

✉ Corresponding author:

wahyuardana78@gmail.com

Article Info

Abstrak

Kata kunci:
Peramalan;
Bahan bakar;
SARIMA;
Kapal X;
Penajam Supply Base (PSB);

Industri energi menghadapi tantangan besar dalam pengelolaan persediaan bahan bakar akibat fluktuasi harga dan permintaan. PT Pertamina Hulu Kalimantan Timur (PHKT) menghadapi isu ini dalam operasional Kapal X, transportasi krusial antara Balikpapan dan Penajam Supply Base (PSB). Ketidakpastian kebutuhan bahan bakar dapat mengganggu mobilitas pekerja dan meningkatkan biaya operasional akibat frekuensi pengiriman yang tinggi. Oleh karena itu, peramalan konsumsi bahan bakar menjadi penting untuk efisiensi dan kelancaran operasional. Tujuan penelitian ini untuk meramalkan jumlah bahan bakar yang akan digunakan Kapal X. Metode yang digunakan yakni pendekatan kuantitatif dengan memanfaatkan data sekunder konsumsi bahan bakar periode Januari hingga September 2024 dari PSB PHKT. Dalam upaya peramalan, digunakan model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) $(1,1,0)(0,1,1)^6$. Pemilihan model ini didasarkan pada signifikansi parameter dan pemenuhan asumsi residi *white noise* setelah melalui uji diagnostik. Hasil penelitian memberikan gambaran prediksi penggunaan bahan bakar Kapal X pada minggu ke-40 sebesar 1794,37 liter.

Abstract

Keywords:
Forecasting;
Fuel;
SARIMA;
Ship X;
Penajam Supply Base(PSB);

The energy industry faces major challenges in fuel inventory management due to price and demand fluctuations. PT Pertamina Hulu Kalimantan Timur (PHKT) faces this issue in the operation of Ship X, the crucial transportation between Balikpapan and Penajam Supply Base (PSB). Uncertainty in fuel demand can disrupt worker mobility and increase operational costs due to the high frequency of deliveries. Therefore, forecasting fuel consumption is important for efficiency and smooth operation. The purpose of this research is to forecast the amount of fuel that will be used by Ship X. The method used is a quantitative approach by utilizing secondary data on fuel consumption for the period January to September 2024 from PSB PHKT. In forecasting efforts, the Seasonal Autoregressive Integrated Moving Average

(SARIMA) $(1,1,0)(0,1,1)^6$ model is used. The selection of this model is based on parameter significance and fulfillment of the white noise residual assumption after going through diagnostic tests. The results of the study provide a prediction of the fuel usage of Ship X in week 40 of 1794.37 liters.

1. PENDAHULUAN

Industri energi menghadapi tantangan besar dalam mengelola persediaan akibat fluktuasi harga dan permintaan yang tidak menentu. Perusahaan harus menyeimbangkan antara ketersediaan bahan baku dan menghindari kelebihan stok. Perusahaan perlu sangat jeli dalam mengelola persediaan di tengah kondisi pasar yang terus berubah (Chopra & Meindl, 2016).

Pertamina Hulu Kalimantan Timur (PHKT) sebagai perusahaan energi nasional memiliki peran penting dalam memenuhi kebutuhan energi di Indonesia. PHKT memiliki Kapal X sebagai transportasi karyawan antara Balikpapan dan Penajam Supply Base (PSB). Kapal ini memiliki peran krusial dalam menjamin mobilitas pekerja yang sebagian besar berdomisili di Balikpapan untuk dapat menjalankan tugas mereka di PSB. Dengan demikian, operasional Kapal X sangat berpengaruh terhadap kelancaran aktivitas di PSB. Kapal X yang mengantar para pekerja PSB dapat mengangkut 20 penumpang untuk sekali perjalanan, dalam sehari kapal penumpang melakukan 3 kali keberangkatan dan 3 kali penjemputan, berikut jadwal dari kapal penumpang. Jarak yang ditempuh kapal X untuk sekali perjalanan adalah 6.5 km, untuk kecepatannya sekitar 10 knot. Kapal X dalam kesehariannya melakukan pengisian bahan bakar di PSB.

Keberlangsungan operasional Kapal X sangat bergantung pada ketersediaan bahan bakar yang cukup. Untuk memenuhi kebutuhan bahan bakar yang fluktuatif, pengiriman dilakukan 3-4 kali dalam sebulan. Namun, frekuensi pengiriman yang tinggi ini berdampak pada biaya operasional. Oleh karena itu, peramalan konsumsi bahan bakar menjadi sangat penting untuk menghindari pemborosan dan memastikan kelancaran operasional kapal X.

Pemilihan metode peramalan yang tepat memerlukan pemahaman terhadap karakteristik pola data (horizontal, musiman, siklus, dan tren), mengingat setiap metode memiliki keunggulan dan keterbatasan dalam hal akurasi, ruang lingkup, rentang waktu, dan biaya. Data yang diperoleh dalam penelitian ini memperlihatkan pola tren, yang berarti adanya pergerakan data ke atas atau ke bawah dalam periode waktu yang panjang. Dengan demikian, metode peramalan yang relevan untuk data dengan pola tren di antaranya adalah *Seasonal Autoregression Integrated Moving Average* (SARIMA). SARIMA ialah teknik peramalan deret waktu yang digunakan untuk data dengan fluktuasi musiman (Fahrudin & Sumitra, 2020). Sebagai pengembangan dari model ARIMA, SARIMA mewarisi keunggulan ARIMA dalam peramalan jangka pendek. ARIMA sendiri terbukti memiliki ketepatan yang baik untuk data *time series* non-stasioner selama data tersebut menunjukkan pola linear (Munarsih, 2011). Salah satu kelebihan utama ARIMA adalah fleksibilitasnya dalam menyesuaikan diri dengan karakteristik data. Selain itu, metode ini mampu memberikan hasil peramalan dengan tingkat akurasi yang memuaskan dan dianggap sebagai pilihan yang cepat, sederhana dalam implementasi, relatif akurat, serta terjangkau untuk meramalkan beberapa variabel. (Kolker, 2011). Metode ini kemudian dapat diusulkan kepada Penajam Supply Base (PSB) Pertamina Hulu Kalimantan Timur untuk peramalan bahan bakar kapal X.

2. METODE

2.1 SARIMA

SARIMA ialah teknik peramalan deret waktu yang digunakan untuk data dengan fluktuasi musiman (Fahrudin & Sumitra, 2020). Metode ini merupakan perkembangan dari model ARIMA . Dalam konteks ini, pola musiman dalam model ARIMA atau SARIMA bisa direpresentasikan sebagai ARIMA(p, d, q)(P, D, Q) s , dengan " p, d, q " mewakili ordo Autoregressive, differencing, dan Moving Average untuk komponen non-musiman, " P, D, Q " mewakili ordo Autoregressive, differencing, dan Moving Average untuk komponen musiman, serta " s " menunjukkan jumlah periode dalam satu musim (Arum, Fitriani, & Amri, 2024).

2.2 Stasioneritas

Suatu deret waktu dikatakan stasioner jika prosesnya tidak berubah terhadap waktu. Artinya nilai rata-rata terhadap waktu selalu tetap (Tantika, Supriadi, & Anggraini, 2018). Pada Model ARIMA data yang digunakan haruslah bersifat stasioner atau nilai rata-rata dari datanya tidak berubah sepanjang waktu yang dapat dilihat melalui plot datanya. Apabila 9 data tidak bersifat stasioner maka harus dilakukan konversi data dengan metode diferensiasi. Suatu data dikatakan stasioner dalam ragam jika memiliki nilai *Rounded Value* 1 (Santoso, 2020). Kegunaannya untuk mengatur variansi dalam rangkaian data dan merupakan salah satu teknik yang dimanfaatkan untuk mengubah data yang memiliki variansi yang tidak stabil menjadi data yang memenuhi sifat stasioner terkait variansi (Hillmer & Wei, 1991). Dengan menerapkan transformasi ini, kita dapat mengartikan rangkaian data baru sebagai $Z't$.

$$Z't = \frac{z_t^{\lambda} - 1}{\lambda} \quad (1)$$

2.3 Metode Diferensiasi

Metode diferensiasi digunakan untuk melakukan konversi data yang tidak stasioner menjadi data yang stasioner yang merupakan syarat ARIMA dengan cara menghitung selisih nilai data saat ini dengan nilai data sebelumnya. Diferensiasi ber-ordo d , jika data sudah stasioner maka ordonya adalah 0 sehingga menjadi ARIMA ($p,0,q$) atau sering disebut sebagai ARMA. Notasi B (operator *Backshift*) digunakan dalam proses diferensiasi. Penggunaan notasi B dalam diferensiasi secara umum adalah (Rosadi, 2016):

$$B_d X^t = X_{t-d} \quad (2)$$

2.4 Identifikasi Model

Pola ACF dan PACF bisa berpola *cut off* dan *dies down*. Pertama, ACF dan PACF dari data *time series* bisa berpola *cut off*. Pola *cut off* adalah pola ketika garis ACF dan PACF signifikan pada lag pertama atau kedua tetapi kemudian tidak ada garis ACF dan PACF yang signifikan pada *lag* berikutnya. Kedua, ACF dan PACF dikatakan memiliki perilaku *dies down* jika kedua fungsi tersebut tidak terpotong, melainkan menurun 11 secara bertahap. Bentuk penurunannya bisa tanpa ataupun dengan berbentuk gelombang sinus. Penentuan apakah suatu data *time series* dimodelkan dengan AR, MA atau ARIMA tergantung pola ACF dan PACF. Model AR digunakan jika plot ACF-nya *dies down* sementara PACF-nya *cut off*. Model MA digunakan jika plot ACF-nya *cut off* dan plot PACF-nya *dies down*. Sedangkan jika kedua plot ACF dan PACF sama-sama *dies down*, maka model yang digunakan adalah model ARIMA (Rosadi, 2016).

Autocorrelation Function (ACF) untuk time lag $1, 2, \dots, k$ dapat dicari dengan menggunakan rumus autokorelasi, r_k yaitu : (Makridakis, Wheelwright., & McGee, 1999)

$$r_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (3)$$

Dimana:

- r_k = autokorelasi ke- k
- Y_t = data pengamatan ke- t
- \bar{Y} = rata-rata pengamatan
- Y_{t+k} = data pengamatan ke- $t+k$

Partial Autocorrelation Function (PACF) untuk time lag $1, 2, \dots, k$ dapat dicari dengan menggimakan rumus autokorelasi parsial, r_{kk} yaitu : (Bowerman & O'Connel, 1983)

$$r_{kk} = \begin{cases} \frac{r_1}{r_k - \sum_{j=1}^{k-1} (r_{k-1,j})(r_{k-j})} ; & \text{jika } k = 1 \\ \frac{r_1}{1 - \sum_{j=1}^{k-1} (r_{k-1,j})(r_j)} ; & \text{jika } k = 2, 3, \dots \end{cases} \quad (4)$$

Dimana:

- r_{kk} = autokorelasi parsial ke- k
- r_k = autokorelasi ke- k
- r_{k-1} = autokorelasi ke- $k-1$

2.5 Model Autoregresive (AR)

Model *Autoregressive* orde p adalah model hasil regresi dengan dirinya sendiri pada waktu-waktu sebelumnya didefinisikan dengan persamaan (Rosadi, 2016):

$$X_t = a_1x_{t-1} + a_2x_{t-2} + \cdots + a_px_{t-p} + \varepsilon_t \quad (5)$$

Dengan:

$a_1, a_2, \dots, a_p \in \mathbb{R}$

a_p = parameter autoregresif ke-p

ε_t = nilai kesalahan atau error pada saat t

2.6 Model *Moving Average* (MA)

Proses *Moving Average* orde q dapat dituliskan sebagai (Rosadi, 2016):

$$X_t = \varepsilon_t - b_1\varepsilon_{t-1} - \cdots - b_q\varepsilon_{t-q} \quad (6)$$

Dengan

$b_1, b_2, \dots, b_q \in \mathbb{R}$

b_q = parameter moving average ke-q

ε_{t-q} = nilai kesalahan atau error pada saat t-q

2.7 Model Autoregresive Moving Average (ARMA)

Untuk proses *Autoregressive Moving Average* adalah gabungan dari kedua proses sebelumnya yaitu *Autoregresive* dan *Moving Average* tanpa adanya proses differensiasi sehingga dapat dituliskan sebagai (Nany Salwa, 2018):

$$X_t = a_1x_{t-1} + a_2x_{t-2} + \cdots + a_px_{t-p} + \varepsilon_t - b_1\varepsilon_{t-1} - \cdots - b_q\varepsilon_{t-q} \quad (7)$$

2.8 Model Autoregresive Integrated Moving Average (ARIMA)

Model yang umum digunakan dalam ARIMA *Box Jenkins* adalah model AR (*autoregressive*), MA (*moving average*), dan ARMA (*autoregressive-moving average*). Menurut *Box-Jenkins*, model *time series* yang tidak stasioner dapat dikatakan sebagai proses *Autoregressive Integrated Moving Average* orde (p,d,q) atau disingkat ARIMA (p,d,q) dimana p adalah orde dari parameter *autoregressive* (AR), d adalah besaran yang menyatakan berapa kali dilakukan *differencing* sehingga proses menjadi stasioner dan q adalah orde dari parameter *moving average* (MA). Secara umum model ARIMA (p,d,q) dapat ditulis sebagai berikut (Wei, 1990).

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta_q(B)a_t \quad (8)$$

dengan:

ϕ_p : Koefisien komponen AR dengan orde p

θ_q : Koefisien komponen MA dengan orde q

d : Orde *differencing*

B : Operator *shift backward*

y_t : Data *time series* ke-t

a_t : Residual ke-t.

2.9 Model Seasonal Autoregresive Integrated Moving Average (SARIMA)

SARIMA merupakan teknik peramalan deret waktu yang digunakan untuk data dengan fluktuasi musiman (Fahrudin & Sumitra, 2020). Metode ini merupakan perkembangan dari model ARIMA. Dalam konteks ini, pola musiman dalam model ARIMA atau SARIMA bisa direpresentasikan sebagai ARIMA(p, d, q)(P, D, Q)s, dengan "p, d, q" mewakili ordo *Autoregressive*, *differencing*, dan *Moving Average* untuk komponen non-musiman, "P, D, Q" mewakili ordo *Autoregressive*, *differencing*, dan *Moving Average* untuk komponen musiman, serta "s" menunjukkan jumlah periode dalam satu musim (Arum, Fitriani, & Amri, 2024). Model SARIMA bisa direpresentasikan dalam bentuk persamaan sebagai berikut:

$$\phi_p(B^s)\emptyset_p(B)(1 - B)^d(1 - B^s)^D z_t = \Theta_q(B)\emptyset_Q(B^s)\alpha \quad (9)$$

Dimana :

$\emptyset_p(B)$: AR Non Seasonal

$\phi_p(B^s)$: AR Seasonal

$(1 - B)^d$: differencing non seasonal

$(1 - B^s)^D$: differencing seasonal

$\Theta_q(B)$: MA non seasonal

$\emptyset_Q(B^s)$: MA seasonal

2.10 Operator Shift Backward

Operator *shift backward* dinotasikan dengan B, dipakai untuk menunjukkan pemunduran satu periode. Jadi B yang dioperasikan pada X_t mempunyai pengaruh memindahkan perhatian ke X_{t-1} (Aries, 2004).

2.11 Metode Ljung-Box dan Pemilihan Model Terbaik

Suatu model bersifat white noise artinya residual dari model tersebut telah memenuhi asumsi identik (variasi residual homogen) serta independen (antar residual tidak berkorelasi). Pengujian asumsi white noise dilakukan dengan menggunakan uji Ljung-Box (Maliangkay, 2018). Model dikatakan baik jika nilai error bersifat random, artinya sudah tidak mempunya pola tertentu lagi. Untuk melihat kerandoman nilai error dilakukan pengujian terhadap nilai koefisien autokorelasi dari nilai error dengan metode Ljung-Box (Desvina & Desmita, 2015):

$$Q = n'(n' + 2) \sum_{k=1}^m \frac{r_k^2}{(n'-k)} \quad (10)$$

Dengan: $n' = n - (d + SD)$

d = ordo diferensiasi bukan faktor musim

D = ordo diferensiasi faktor musiman

S = jumlah periode per musim

m = lag waktu maksimum

Kriteria Pengujian :

1. Jika $Q \leq \chi^2$ berarti nilai error bersifat random dan model dapat diterima.
2. Jika $Q > \chi^2$ berarti nilai error tidak bersifat random dan model tidak dapat diterima.

Jika masih terdapat lebih dari satu model , maka untuk menentukan model terbaik dapat menggunakan rata-rata persentase kesalahan terkecil dengan MSE (Zulhamidi & Hardianto, 2017):

$$MSE = \frac{\sum e^2}{n}$$

Dengan:

e = selisih nilai asli dengan peramalan

n = banyak data

3. HASIL DAN PEMBAHASAN

3.1 Data

Data yang digunakan adalah jumlah pengisian bahan bakar pada kapal X dari januari 2024 hingga september 2024 (PSB PHKT, 2024). Data yang digunakan berupa data dengan satuan mingguan. Dibawah ini merupakan gambaran ringkas dari data tersebut yang menjadi fokus dalam penelitian kami.

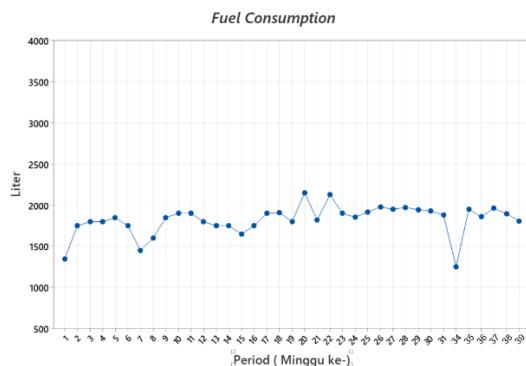
Tabel 1. Data mingguan Fuel kapal X

Minggu	Liter	Minggu	Liter	Minggu	Liter	Minggu	Liter
1	1350	11	1900	21	1820	31	1880
2	1750	12	1800	22	2130	34	1250
3	1800	13	1750	23	1900	35	1950
4	1800	14	1750	24	1855	36	1860
5	1850	15	1650	25	1920	37	1965
6	1750	16	1750	26	1980	38	1895
7	1450	17	1900	27	1950	39	1810
8	1600	18	1910	28	1975		
9	1850	19	1800	29	1945		
10	1900	20	2150	30	1930		

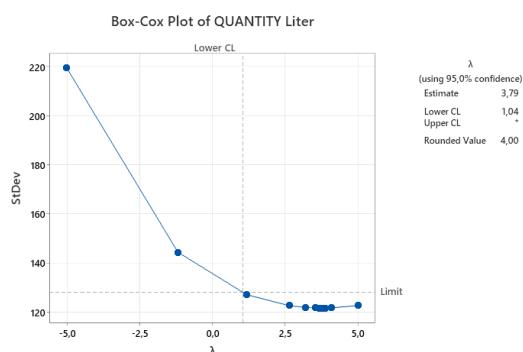
3.2 Identifikasi Model

Identifikasi model stasioneritas dilakukan untuk melihat apakah data stasioner. Stasioner atau tidak stasionernya data, dapat diperoleh dengan *Box-cox Transformation*. Bila data tidak stasioner, maka dilakukan transformasi data. Apabila stasioner data sudah diperoleh, maka selanjutnya melakukan stasioner dengan ACF (fungsi autokorelasi) untuk menganalisa model, apabila model tidak bisa dianalisa maka harus melakukan diffrensiasi.

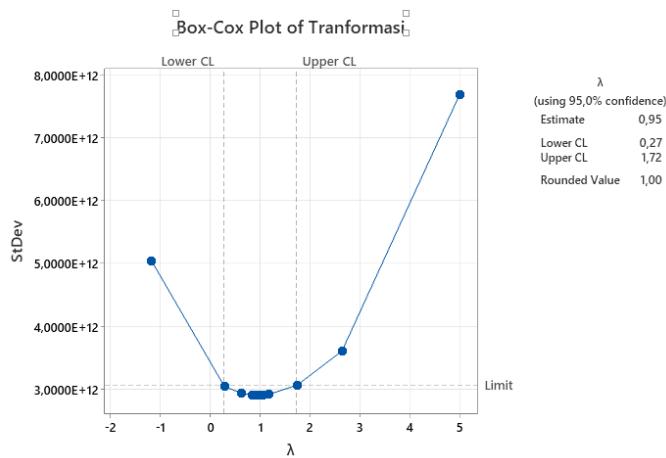
Tahap awal ARIMA adalah identifikasi data. Data diidentifikasi untuk mengetahui kestasionerannya terhadap nilai rata-rata dan nilai ragamnya. Hal ini dilakukan untuk memenuhi syarat asumsi dalam pemodelan ARIMA yaitu harus stasioner terhadap nilai rata-rata dan nilai ragamnya (Maliangkay, 2018). Identifikasi model dilakukan dengan software.

**Gambar 1 Kurva Fuel Consumption**

Dari hasil diatas dapat dilihat data pengisian bahan bakar pola musiman karena terjadi fluktuasi pada waktu tertentu. Pola Musiman adalah Pola yang mengalami fluktuasi dikarenakan data yang periodik dalam kurun waktu kurang dari satu tahun.

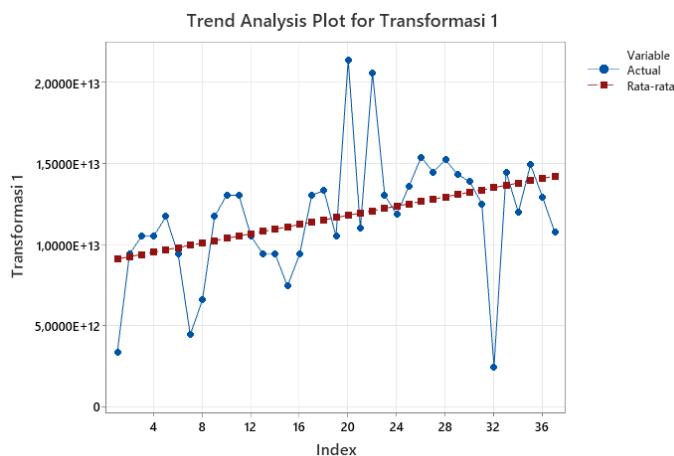
**Gambar 2 Box-Cox Transformation transformasi data asli**

Seperti yang terlihat pada gambar 2 *rounded value* bernilai 4.00, sehingga harus dilakukan transformasi data lagi agar data stasioner di *rounded value* bernilai 1,00.



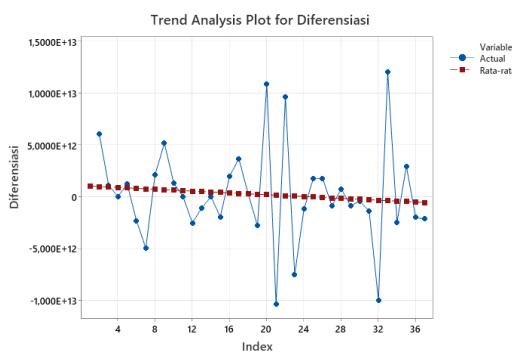
Gambar 3 Box-Cox Transformasi data hasil transformasi

Setelah dilakukan transformasi, *rounded value* diperoleh sebesar 1,00. nilai Hasil rounded tersebut menunjukkan bahwa data permintaan telah mencapai stasioneritas dalam ragam. Berikutnya data akan dicek kembali apakah data hasil transformasi tersebut sudah stasioner terhadap rata-rata.



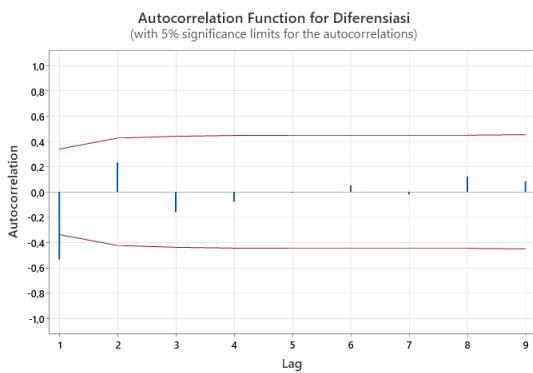
Gambar 4 Plot Trend data transformasi

Berdasarkan kurva diatas dapat dilihat jika data yang sudah ditransformasi masih belum stasioner tehadap rata-rata karena garis rata-rata pada grafik semakin keatas yang artinya rata-ratanya tidak tetap, solusinya adalah dengan melakukan diferensiasi. Berikut hasil diferensiasi:

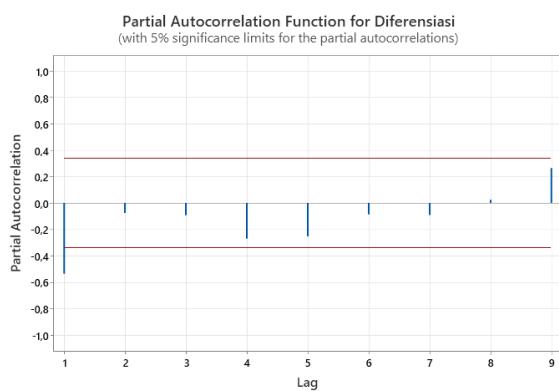


Gambar 5 Plot Trend data diferensiasi

Berdasarkan kurva di atas terlihat bahwa data telah bergerak di sekitar rata-rata . Setelah dilakukan differensiasi maka ditampilkan plot ACF dan plot PACF seperti berikut ini:



Gambar 6: Plot ACF



Gambar 7: Plot PACF

Hasil dari ACF dan PACF data tidak terjadi perubahan nilai rata-rata dan ragam. Jadi data dapat dikatakan sudah stasioner terhadap rata-rata, sehingga tidak perlu dilakukan differencing.

Identifikasi model sementara pada model ARIMA dinotasikan (p,d,q) dengan model p *Autoregressive* (AR) dari grafik *Autocorrelation Function* yang bernilai 1, d adalah difference yang bernilai 1, dan q adalah *Moving Average* (MA) dari grafik *Partial Autocorrelation Function* yang bernilai 1. Maka dapat disimpulkan bahwa model-model yang dapat terbentuk dari ordo p,d,q $(1,1,1)$ adalah model $(0,1,1)$, $(1,1,0)$ dan $(1,1,1)$. Sedangkan model dari SARIMA yaitu $(p,d,q) (P,D,Q)^s$. Ordo d adalah proses differensiasi yang bernilai 1, D adalah proses differensiasi musiman yang bernilai 1, S adalah lambang dari seasonal yang bernilai 6 karena mengikuti pola data setiap 6 minggu sekali terjadi perubahan, p adalah *Autoregressive* (AR) dan 1 adalah *Moving Average* (MA) untuk ordo nonseasonal. P adalah *Autoregressive* (AR) dan Q adalah *Moving Average* (MA) untuk ordo seasonal (musiman). Maka dapat disimpulkan bahwa model-model yang dapat terbentuk dari ordo $(p,d,q)(P,S,Q)^s$ adalah $(1,1,1)(1,1,1)^6$, $(1,1,1)(1,1,0)^6$, $(1,1,1)(0,1,1)^6$, $(1,1,0)(1,1,1)^6$, $(1,1,0)(1,1,0)^6$, $(1,1,0)(0,1,1)^6$, $(0,1,1)(1,1,1)^6$, $(0,1,1)(1,1,0)^6$, and $(0,1,1)(0,1,1)^6$.

3.3 Estimasi Model

Langkah estimasi parameter yaitu dengan cara melakukan pengujian signifikansi. Parameter dikatakan signifikan apabila nilai probabilitasnya (P) lebih kecil dari α ($P < \alpha$), dengan selang keperayaan 95% untuk nilai α adalah 0,05. Jika probabilitas lebih besar dari α ($P > \alpha$) maka nilai untuk parameter model ditolak sehingga model tidak bisa digunakan untuk peramalan. Estimasi model dilakukan dengan bantuan *software* minitab 21 lalu melakukan analisis nilai P dari model ARIMA dan SARIMA, sebagai berikut:

Tabel 2 Signifikansi model

Model	Type	P	Tingkat Signifikan
(1,1,1)	AR	0,593	
	MA	0,035	Tidak Signifikan
(0,1,1)	MA	0,590	Tidak Signifikan
(1,1,0)	AR	0,764	Tidak Signifikan
	AR	0,959	
	SAR	0,983	
(1,1,1)(1,1,1) ⁶	MA	0,787	Tidak Signifikan
	SMA	0,980	
	AR	0,867	
(1,1,1)(1,1,0) ⁶	SAR	0,784	Tidak Signifikan
	MA	0,705	
	AR	0,958	
(1,1,1)(0,1,1) ⁶	MA	0,828	Tidak Signifikan
	SMA	0,625	
	AR	0,801	
(1,1,0)(1,1,1) ⁶	SAR	0,998	Tidak Signifikan
	SMA	0,997	
(1,1,0)(1,1,0) ⁶	AR	0,657	
	SAR	0,668	Tidak Signifikan
(1,1,0)(0,1,1) ⁶	AR	0,000	Signifikan
	SMA	0,049	
	SAR	0,997	
(0,1,1)(1,1,1) ⁶	MA	0,372	Tidak Signifikan
	SMA	0,996	
(0,1,1)(1,1,0) ⁶	SAR	0,798	Tidak Signifikan
	MA	0,123	
(0,1,1)(0,1,1) ⁶	MA	0,633	Tidak Signifikan
	SMA	0,689	

Berdasarkan hasil uji signifikansi menunjukkan bahwa terdapat 1 model SARIMA yang signifikan yaitu model SARIMA (1,1,0)(0,1,1)⁶. Dikarenakan hanya 1 model SARIMA yang signifikan maka dapat langsung melakukan *forecasting fuel consumption* Kapal X.

3.4 Peramalan Fuel Consumption

Berikut hasil model SARIMA (1,1,0)(0,1,1)⁶ untuk 13 minggu kedepan.

Tabel 4 Hasil Forecasting

Minggu	Forecasting
40	1794,37
41	1905,12
42	1961,61
43	1950,93
44	1935,94
45	1795,04
46	1809,97
47	1904,01
48	1969,63
49	1953,96
50	1941,70
51	1799,31
52	1815,05

Berdasarkan Tabel 4 yang menyajikan hasil *forecasting* untuk 13 minggu ke depan, terlihat adanya fluktuasi nilai *forecasting* dari minggu ke minggu. Pada awal periode *forecasting* (minggu ke-40 hingga ke-42), nilai *forecasting* cenderung meningkat. Setelah itu, terdapat penurunan pada minggu ke-43 dan ke-44. Kemudian, diikuti penurunan signifikan pada minggu ke-45. Selanjutnya, pada minggu ke-46 hingga ke-49, nilai *forecasting* kembali menunjukkan tren peningkatan. Setelah mencapai puncaknya pada minggu ke-48 dan ke-49, terjadi penurunan kembali pada minggu ke-50. Dua minggu terakhir periode *forecasting* (minggu ke-51 dan ke-52) menunjukkan kenaikan kembali, meskipun tidak setinggi nilai pada minggu-minggu sebelumnya.

Secara keseluruhan, hasil *forecasting* 13 minggu ke depan menunjukkan adanya pola yang tidak sepenuhnya stabil, dengan beberapa kali mengalami kenaikan dan penurunan. Pola ini kemungkinan dipengaruhi oleh komponen musiman dengan lag 6, sebagaimana tercermin dalam model SARIMA yang digunakan.

4. KESIMPULAN

Dari hasil identifikasi untuk peramalan didapatkan model SARIMA $(1,1,0)(0,1,1)^6$ untuk melakukan *forecsating*. Forecasting 13 minggu mendatang menunjukkan fluktuasi nilai, dimulai dengan 1794,37 liter pada minggu ke-40. Awalnya meningkat (minggu 40-42), lalu menurun (minggu 43-45), kemudian naik lagi (minggu 46-49) sebelum kembali turun (minggu 50) dan sedikit naik di akhir (minggu 51-52). Pola tidak stabil ini diduga dipengaruhi oleh musiman dengan lag 6, sesuai model SARIMA.

5. REFERENSI

- Aries, F. (2004). *Peramalan Jumlah Produksi Granit Dengan Model Arima (Studi Kasus Pada PT. Karimun Granite, Tanjung Balai Karimun, Riau)*. Yogyakarta: Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia.
- Arum, P. R., Fitriani, I., & Amri, S. (2024). Pemodelan Seasonal Autoregressive Integrated Moving Average (SARIMA) Untuk Meramalkan Volume Angkutan Barang Kereta Api Di Pulau Jawa Tahun 2021 . *Journal Of Data Insights*, 26-35.
- Aziz, S., Sayuti, A., & Mustakim. (2017). Penerapan Metode ARIMA Untuk Peramalan Pengunjung Perpustakaan UIN Suska Riau. *Seminar Nasional Teknologi Informasi, Komunikasi Dan Industri (SNTIK)*, 186-193.
- Bowerman, B. L., & O'Connel, R. T. (1983). *Time Series And Forecasting* .
- Chopra, S., & Meindl, P. (2016). *Supply Chain Management: Strategy, Planning, And Operation*. Pearson.
- Desvina, A. P., & Desmita, E. (2015). Penerapan Metode Box-Jenkins Dalam Meramalkan Indeks Harga Konsumen Di Kota Pekanbaru. *Jurnal Sains Matematika Dan Statistika*, 39-47.
- Diebold, F. X. (2006). *Elements Of Forecasting*. 5191 Natorp Boulevard Mason, OH 45040 USA: South-Western College Pub.
- Fahrudin, R., & Sumitra, I. D. (2020). Peramalan Inflasi Menggunakan Metode Sarima Dan Exponential Smoothing. *Majalah Ilmiah UNIKOM* .
- Fahrudin, R., & Sumitra, I. D. (2020). *Peramalan Inflasi Menggunakan Metode Sarima Dan Exponential Smooting*. Unkom.
- Fahrudin, R., & Sumitra, I. D. (2020). Peramalan Inflasi Menggunakan Metode Sarima Dan Single Exponential Smoothing (Studi Kasus; Kota Bandung). *Majalah Ilmiah UNIKOM*.
- Hillmer, S. C., & Wei, W. W. (1991). Time Series Analysis: Univariate And Multivariate Methods. *Journal Of The* , 86(413),245.
- Kolker, A. (2011). *Forecasting Time Series. Healthcare Management Engineering: What*. Milwaukee: Springer Science Business.
- Makridakis, S. S., Wheelwright., & Mcgee. (1999). *Metode Aplikasi Dan Peramalan*. Edisi 2. Jilid I. Jakarta: Binarupa Aksara.
- Maliangkay, N. C. (2018). *Penggunaan Metode ARIMA, Variasi Kalender, Dan Interventensi Untuk Meramalkan Inflasi Kabupaten Sidoarjo*. Surabaya: Faculty Of Mathematics, Computations, And Data Sciences Sepuluh Nopember Institute Of Technology .
- Munarshih, E. (2011). *Penerapan Model Arima-Neural Network Hybrid Untuk Peramalan Time Series; The Implementation Of Arima-Neural Network Hybrid Model For Time Series Forecasting*.

- Nany Salwa, N. T. (2018). Peramalan Harga Bitcoin Menggunakan Metode ARIMA. *Journal Of Data Analysis*, 21-31.
- PSB PHKT. (2024). *Log Activity Fuel*.
- Rosadi, D. (2016). *Analisis Runtun Waktu Dan Aplikasinya Dengan R*. Yogyakarta: Gadjah Mada University Press.
- Santoso, R. J. (2020). *Penggunaan Metode ARIMA Dengan Aplikasi MINITAB Untuk Peramalan Data Pendapatan Perusahaan Pecah Batu Putra Mandiri*. Semarang: UIN Walisongo Semarang.
- Tantika, H. N., Supriadi, N., & Anggraini, D. (2018). Metode Seasonal ARIMA Untuk Meramalkan Produksi Kopi Dengan Indikator Curah Hujan Menggunakan Aplikasi R Di Kabupaten Lampung Barat. *Matematika*, 49-58.
- Wei, W. W. (1990). *Time Series Analysis: Univariate And Multivariate Methods*. USA: Addison-Wesley Publishing Company.
- Zulhamidi, Z., & Hardianto, R. (2017). Peramalan Penjualan Teh Hijau Dengan Metode Arima (Studi Kasus Pada PT. Mk). *PASTI*, 231-244.