

Forecasting Smallholder Oil Palm Yield in Riau Province through the SARIMA Approach

Septirina Kiki Arisandi, Dony Permana*, dan Tessy Octavia Mukhti

Departemen Statistika, Universitas Negeri Padang, Padang, Indonesia

*Corresponding author: donypermana@fmipa.unp.ac.id

Submitted : 28 Oktober 2025

Revised : 26 Januari 2026

Accepted : 27 Januari 2026

ABSTRACT

Oil palm stands as one of Indonesia's major agricultural sectors that plays a vital role in regional economic growth, particularly within Riau Province. However, its production often fluctuates due to seasonal and environmental factors, making accurate forecasting essential for planning and policy formulation. This study aims to forecast smallholder oil palm production in Riau Province through the Seasonal Autoregressive Integrated Moving Average (SARIMA) Approach. The data consist of monthly oil palm production from January 2006 to December 2023 obtained from the Central Bureau of Statistics (BPS) of Riau Province. The modeling process includes identifying the model structure, estimating parameters, performing diagnostic checks, and evaluating forecasting accuracy using the Mean Absolute Percentage Error (MAPE). The best model selected was SARIMA (2,0,0)(0,1,1)[12] with an AIC value of 4980.12 and a MAPE of 11.27%, indicating a good level of accuracy. The model effectively captured both seasonal and long-term trend patterns in production. The forecast results suggest that peak production typically occurs in August–September, while the lowest occurs in February–March. The study concludes that the SARIMA model provides a robust statistical framework for predicting oil palm production and can be applied as a decision-support tool in agricultural and economic planning for the province.

Keywords: Forecasting, Oil Palm, Riau Province, SARIMA, Time Series.



This is an open access article under the Creative Commons 4.0 Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. ©2022 by author and Universitas Negeri Padang.

I. PENDAHULUAN

Kelapa sawit dikenal sebagai komoditas pertanian unggulan yang memiliki kontribusi besar terhadap perekonomian nasional maupun daerah. Provinsi Riau merupakan salah satu daerah dengan luas areal perkebunan kelapa sawit terbesar di Indonesia, di mana sebagian besar lahannya dikelola oleh perkebunan rakyat berdasarkan data *Statistik Kelapa Sawit Provinsi Riau 2022* yang diterbitkan oleh Badan Pusat Statistik (BPS) Provinsi Riau (Redaksi, 2024). Kondisi ini menunjukkan besarnya ketergantungan ekonomi daerah terhadap sektor perkebunan sawit. Namun demikian, produksi kelapa sawit di Provinsi Riau tidak selalu stabil. Fluktuasi produksi terjadi dari waktu ke waktu akibat pengaruh berbagai faktor seperti kondisi iklim, masa panen, serta perubahan pola produksi. Ketidakstabilan produksi tersebut dapat memengaruhi ketersediaan bahan baku industri pengolahan dan menghambat perencanaan kebijakan yang efektif di bidang pertanian dan perdagangan.

Oleh karena itu, dibutuhkan suatu pendekatan statistik yang mampu melakukan peramalan produksi secara akurat sehingga hasilnya dapat dijadikan pedoman untuk pengambilan keputusan dan perencanaan pembangunan daerah. Analisis deret waktu menjadi salah satu metode yang tepat untuk mengidentifikasi pola, tren, dan fluktuasi musiman pada data produksi. Di antara berbagai model peramalan deret waktu, metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dinilai mampu menangkap pola musiman serta kecenderungan jangka panjang secara lebih komprehensif (Nurfritri Imro'ah, 2019).

Beberapa penelitian sebelumnya telah memanfaatkan model SARIMA, penelitian oleh (Arunika et al., 2021) berjudul "*Perbandingan Model SARIMA, Exponential Smoothing, dan XGBoost untuk Prediksi Penjualan Super Store*" menunjukkan bahwa model SARIMA (0,0,0) (1,0,2)¹² memberikan hasil terbaik dengan nilai R^2 sebesar 0,932. Hasil ini menunjukkan bahwa model SARIMA tidak hanya mampu menangkap pola musiman dan tren dalam data, tetapi juga menghasilkan akurasi yang lebih unggul dibandingkan metode lainnya. Selanjutnya, penelitian oleh (Junaedi et al.,

2025) berjudul “Penerapan Metode Seasonal ARIMA (SARIMA) untuk Peramalan Penjualan Barang dengan Pola Musiman Tahunan” juga membuktikan efektivitas model SARIMA dalam meningkatkan akurasi peramalan permintaan barang musiman. Berdasarkan Hasil penelitian tersebut ditunjukkan bahwa model SARIMA memberikan nilai RMSE, MAE, dan MAPE yang lebih rendah dibandingkan model ARIMA konvensional, sehingga dinilai lebih baik dalam menggambarkan pola musiman tahunan dan mengurangi potensi overstock maupun stockout pada sistem inventori.

Penelitian ini dilakukan untuk mengisi kesenjangan kajian terdahulu dengan menggunakan pendekatan model SARIMA dalam prediksi produksi kelapa sawit di tingkat perkebunan rakyat di Provinsi Riau. Pendekatan ini diharapkan mampu menganalisis pola musiman serta tren jangka panjang dengan tingkat akurasi yang akurat dibandingkan metode konvensional. Tujuan utama penelitian ini adalah mengembangkan model peramalan yang andal untuk menggambarkan pola variasi produksi kelapa sawit serta memberikan gambaran prospektif terhadap perubahan produksi di periode mendatang. Hasil penelitian ini diharapkan dapat menjadi masukan yang bermanfaat bagi pemerintah daerah, pelaku industri, serta pihak lain yang terkait dalam merumuskan strategi pengelolaan dan kebijakan pembangunan sektor perkebunan kelapa sawit yang berkelanjutan.

II. METODE PENELITIAN

A. Sumber Data dan Variabel Penelitian

Penelitian ini menggunakan data sekunder yang diperoleh dari publikasi *Statistik Kelapa Sawit Provinsi Riau Tahun 2023* yang diterbitkan oleh Badan Pusat Statistik (BPS) Provinsi Riau. Data tersebut berupa deret waktu bulanan produksi kelapa sawit pada perkebunan rakyat di Provinsi Riau selama periode Januari 2006 hingga Desember 2023, dengan satu variabel utama yaitu jumlah produksi kelapa sawit (dalam ton). Data ini bersifat kuantitatif dan berkelanjutan (*continuous time series*), sehingga sesuai untuk dianalisis menggunakan pendekatan model deret waktu musiman seperti SARIMA.

B. Teknik Analisis Data

Proses pengolahan analisis data dilakukan dengan menggunakan bantuan perangkat lunak *R Studio*. Adapun tahapan analisis data yang dilakukan yaitu sebagai berikut:

1. Eksplorasi dan Visualisasi Data

Eksplorasi dan visualisasi data dilakukan untuk memperoleh pemahaman awal mengenai karakteristik data produksi kelapa sawit sebelum dilakukan analisis lebih lanjut. Teknik ini digunakan untuk mengidentifikasi nilai rata-rata, maksimum, minimum, serta sebaran data produksi, sedangkan plot data produksi kelapa sawit disajikan untuk memperlihatkan pola tren dan musiman yang terdapat selama periode pengamatan.

2. Uji Stasioneritas

Dalam penelitian ini, stasioneritas data runtun waktu diuji menggunakan pendekatan uji akar unit. Uji ini berfungsi memeriksa apakah suatu akar unit terdapat dalam data, dengan hipotesis yang dirumuskan seperti berikut (Febiola et al., 2024):

H_0 : Data tidak stasioner terhadap rata-rata (data terdapat akar unit)

H_1 : Data stasioner terhadap rata-rata (data tidak terdapat akar unit)

Pengambilan keputusan dilakukan berdasarkan nilai probabilitas (*p-value*), di mana hipotesis nol (H_0) ditolak ketika nilai *p-value* lebih kecil daripada tingkat signifikansi (α). Dengan demikian, dapat disimpulkan bahwa data sudah memenuhi asumsi stasioneritas terhadap rata-rata.

Selain stasioneritas terhadap rata-rata, stasioneritas juga dilakukan terhadap varians menggunakan metode Box-Cox, yang bertujuan untuk menstabilkan varians data. Data dikatakan stasioner terhadap varians apabila nilai parameter Box-Cox (λ) mendekati satu atau selang kepercayaan λ mencakup nilai satu, yang mengindikasikan bahwa varians data telah stabil sehingga tidak diperlukan transformasi lanjutan. Apabila varians belum stasioner, maka dilakukan transformasi Box-Cox yang sesuai.

3. Identifikasi Model (ACF & PACF)

Penentuan model dilakukan berdasarkan analisis plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Tahap ini bertujuan untuk menentukan orde komponen *autoregressive* (AR), *moving average* (MA), serta pola musiman yang mungkin terdapat pada data.

4. Estimasi & Uji Signifikansi Parameter Model SARIMA

Estimasi parameter pada model SARIMA dilakukan untuk memperoleh nilai parameter yang memberikan hasil peramalan paling akurat. Secara umum, bentuk model SARIMA dapat dinyatakan sebagai SARIMA (p, d, q) (P, D, Q)^s, dengan persamaan umum model SARIMA dituliskan di bawah ini (Ruhiat et al., 2022):

$$\phi_p(B^s)\phi_p(B)(1-B)^d(1-B^s)^D Z_t = \theta_q(B)\theta_q(B^s)\alpha_t \quad (1)$$

dengan :

Z_t : nilai data deret waktu pada periode ke-t dengan rata-rata μ , $(1-B)^d$: proses *differencing* non-musiman, $(1-B^s)^D$: proses *differencing* musiman, $\phi_p(B)$: komponen *autoregressive* non-musiman, $\theta_q(B)$: komponen *moving average* non-musiman, $\phi_p(B^s)$: komponen *autoregressive* musiman, $\theta_q(B^s)$: komponen *moving average* musiman dan α_t : nilai residu pada periode ke t.

Setelah kandidat model ditentukan, tahap selanjutnya adalah mengestimasi parameter, ini bertujuan guna mengetahui nilai koefisien dari masing-masing model dan menguji signifikansinya agar model yang dipilih benar-benar dapat merepresentasikan data dengan baik. Hipotesis untuk uji signifikansi parameter ini yaitu sebagai berikut.

H_0 : Koefisien tidak berdampak signifikan terhadap model

H_1 : Koefisien berdampak signifikan terhadap model.

Taraf signifikansi (α) = 5%

Dengan kriteria uji yakni tolak H_0 jika nilai *p-value* < α (0.05).

5. Pemilihan Model Terbaik

Model terbaik dipilih dengan membandingkan nilai kriteria tertentu, seperti *Akaike Information Criterion* (AIC). Berdasarkan kriteria AIC, model yang terpilih adalah yang memiliki nilai AIC yang lebih rendah karena mampu menjelaskan data secara lebih baik tanpa menambah kompleksitas model.

6. Uji Diagnostik

Terdapat dua jenis uji diagnostik yang dilakukan yaitu sebagai berikut.

a. Uji White Noise

Uji *white noise* diterapkan guna menguji apakah residual (sisaan) model telah bersifat acak dan tidak menunjukkan pola tertentu, sehingga dapat dianggap sebagai noise murni (*white noise*). Hipotesis untuk uji *white noise* ini adalah:

H_0 : Model *white noise*

H_1 : Model tidak *white noise*

Taraf signifikansi (α) = 5%

Dengan kriteria uji yakni tolak H_0 jika nilai *p-value* < α (0.05).

b. Uji Normalitas

Uji normalitas residual bertujuan untuk memastikan bahwa residual dari model mengikuti distribusi normal. Dalam penelitian ini digunakan uji *Shapiro-Wilk* untuk mengecek apakah residual dari model sudah berdistribusi normal atau tidak. Uji ini mengukur kesesuaian distribusi residual dengan distribusi normal. Berikut hipotesis untuk uji normalitas residual:

H_0 : Residual dari model berdistribusi normal

H_1 : Residual dari model tidak berdistribusi normal

Taraf signifikansi (α) = 5%

Dengan kriteria uji yakni tolak H_0 jika nilai *p-value* < α (0.05).

7. Peramalan dengan Model Terbaik

Setelah model terbaik diperoleh, tahap selanjutnya adalah melakukan peramalan pada periode mendatang. Peramalan dilakukan untuk mengetahui nilai prediksi, sehingga dapat memberikan gambaran mengenai perkembangan produksi di masa depan.

8. Akurasi Peramalan

Tahap terakhir adalah mengevaluasi akurasi hasil peramalan dengan MAPE. Perhitungan MAPE secara matematis direpresentasikan dengan persamaan:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \quad (2)$$

dengan :

Y_t : nilai observasi/data sebenarnya pada periode ke-t

$\hat{Y}_t$: nilai hasil peramalan/estimasi pada periode ke-t

n : jumlah total titik data

Evaluasi ini dilakukan guna mengukur tingkat akurasi model apakah mampu memprediksi data dibandingkan dengan kondisi sebenarnya. Terdapat analisa terkait kriteria nilai MAPE yang disajikan dalam Tabel 1 berikut.

Tabel 1. Kriteria Nilai MAPE

Nilai MAPE	Kriteria
< 10%	Kinerja Optimal
10% – 20%	Kinerja Baik
20% – 50%	Kinerja Cukup
> 50%	Kinerja Kurang

Sumber : Ruhiat et al., (2022)

III. HASIL DAN PEMBAHASAN

A. Eksplorasi dan Visualisasi Data


Analisis deskriptif digunakan guna melihat karakteristik suatu data untuk mengetahui gambaran umum dari variabel yang digunakan. Tabel 2 menyajikan ringkasan statistik dari variabel Jumlah Produksi Kelapa Sawit di Provinsi Riau pada Januari 2006 hingga Desember 2023.

Tabel 2. Statistika Deskriptif

Variabel	Rata-rata	Simpangan Baku	Maksimum	Minimum
Produksi (Ton)	307.562	101.876	517.607	69.230

Pada tabel 2, ditunjukkan bahwa selama periode Januari 2006 hingga Desember 2023, rata-rata produksi kelapa sawit per bulan tercatat sebesar 307.562 ton, yang menunjukkan kapasitas produksi bulanan secara umum selama 18 tahun tersebut. Simpangan baku sebesar 101.876 ton mengindikasikan bahwa terdapat variasi atau penyebaran produksi bulanan yang cukup tinggi dari nilai rata-ratanya, menunjukkan fluktuasi antar bulan atau tahun. Nilai maksimum sebesar 517.607 ton mencerminkan bulan dengan produksi tertinggi, sementara nilai minimum sebesar 69.230 ton menunjukkan bulan dengan produksi terendah selama periode pengamatan. Secara keseluruhan, hal ini menunjukkan bahwa produksi kelapa sawit mengalami variasi signifikan dari waktu ke waktu.

Selain itu juga ditampilkan plot dari data produksi kelapa sawit bulanan perkebunan rakyat dari Januari 2006 – Desember 2023 sebagai berikut.



Gambar 1. Plot Produksi Kelapa Sawit Perkebunan Rakyat

Berdasarkan Gambar 1, produksi kelapa sawit di Provinsi Riau menunjukkan kecenderungan meningkat dari tahun 2006 hingga 2023 dengan fluktuasi yang cukup nyata di setiap periode. Peningkatan tersebut terlihat beriringan dengan adanya pola naik-turun yang berulang hampir setiap tahun. Pola ini menunjukkan bahwa data produksi kelapa sawit memiliki unsur tren jangka panjang dan komponen musiman yang kuat. Kondisi tersebut mengindikasikan bahwa model deret waktu dengan unsur musiman, seperti SARIMA, sesuai diterapkan untuk menganalisis dan meramalkan pola produksi kelapa sawit di Provinsi Riau.

B. Uji Stasioneritas


Pengujian stasioneritas ini menggunakan uji *Augmented Dickey-Fuller* (ADF). Hasil pengujian ditampilkan pada tabel 3.

Tabel 3. Uji Stasioneritas Data

Uji	P – value
<i>Augmented Dickey-Fuller Test</i>	0.01

Berdasarkan hasil yang terdapat pada tabel 3, diperoleh nilai p -value sebesar 0,01. Artinya nilai p -value lebih kecil dibandingkan taraf signifikansi umum ($\alpha = 0,05$), sehingga dapat ditarik kesimpulan bahwa data deret waktu produksi kelapa sawit bersifat stasioner terhadap rata-rata.


Untuk memastikan tidak terdapat pengaruh musiman yang tersisa, pengujian stasioneritas terhadap rata-rata juga dilakukan pada data hasil seasonal differencing. Berdasarkan uji ADF yang telah dilakukan diperoleh nilai p -value sebesar 0,01, sehingga dapat disimpulkan bahwa data setelah dilakukan seasonal differencing juga bersifat stasioner terhadap rata-rata. Plot dari data hasil seasonal differencing ditunjukkan pada Gambar berikut ini.



Gambar 2. Plot Seasonally Differencing Produksi Kelapa Sawit Perkebunan Rakyat

Berdasarkan Gambar 2, ditunjukkan bahwa fluktuasi pada data produksi kelapa sawit perkebunan rakyat cenderung berpusat di sekitar rata-rata konstan tanpa adanya pola trend maupun musiman yang kuat. Hal ini semakin memperkuat hasil uji ADF bahwa data sudah memenuhi asumsi stasioneritas terhadap rata-rata.


Selain stasioneritas terhadap rata-rata, pengujian stasioneritas juga dilakukan terhadap varians data. Berdasarkan hasil yang diperoleh dari metode Box-Cox pada data seasonal differencing, diperoleh nilai parameter λ sebesar 0,89. Nilai λ tersebut berada cukup dekat dengan nilai satu, yang mengindikasikan bahwa varians data telah relatif stabil. Dengan demikian, data telah memenuhi asumsi stasioneritas terhadap varians, sehingga tidak diperlukan transformasi lanjutan terhadap data. Hasil pengujian stasioneritas terhadap varians ini ditunjukkan pada gambar berikut ini.



Gambar 3. Plot Box-Cox (Log-Likelihood vs Lamda)

C. Identifikasi Model (ACF & PACF)

Setelah data memenuhi asumsi kestasioneran, tahap selanjutnya adalah mengidentifikasi model SARIMA dengan menganalisis plot ACF untuk menentukan orde MA serta plot PACF untuk menentukan orde AR. Plot ACF dan PACF ditampilkan pada Gambar 3 dibawah ini.



Gambar 3. Plot ACF & PACF Setelah Seasonal Differencing

Berdasarkan Gambar 3 plot ACF memperlihatkan spike signifikan pada lag 1 yang mengindikasikan adanya ketergantungan jangka pendek dan mengarah pada kemungkinan keberadaan komponen MA orde rendah. Autokorelasi pada lag-lag selanjutnya (hingga sekitar lag 3) masih muncul namun nilainya semakin mengecil dan cenderung berada di sekitar batas signifikansi, sehingga tidak menunjukkan keputusan yang tegas. Sementara itu, plot PACF memperlihatkan spike signifikan pada lag 1 dan lag 2, kemudian diikuti oleh nilai yang relatif kecil pada lag-lag berikutnya, yang mengindikasikan kemungkinan adanya komponen AR hingga orde 2. Secara umum, tidak ditemukan lonjakan autokorelasi yang dominan pada lag-lag yang lebih tinggi, oleh karena itu model dengan orde rendah dinilai cukup untuk menggambarkan pola ketergantungan dalam data.

Sehingga, dapat terbentuk lima alternatif model SARIMA yang kemudian akan diestimasi parameternya sebagai berikut.

1. SARIMA (1,0,0) (0,1,1)¹² : AR(1) dengan komponen musiman MA(1).
2. SARIMA (0,0,1) (0,1,1)¹² : MA(1) dengan komponen musiman MA(1).
3. SARIMA (1,0,1) (0,1,1)¹² : kombinasi AR(1) dan MA(1) dengan komponen musiman MA(1).
4. SARIMA (2,0,0) (0,1,1)¹² : AR(2) dengan komponen musiman MA(1).
5. SARIMA (0,0,2) (0,1,1)¹² : MA(2) dengan komponen musiman MA(1).

D. Estimasi & Uji Signifikansi Parameter Model SARIMA

Berdasarkan kandidat model yang telah ditentukan, tahap selanjutnya melakukan proses estimasi parameter pada masing-masing model SARIMA. Hasil estimasi parameter ini ditampilkan pada Tabel 4 berikut untuk melihat nilai koefisien yang terbentuk serta signifikansinya.

Tabel 4. Estimasi & Uji Signifikansi Parameter

Model SARIMA	Parameter	Estimasi	P-value	Keterangan
SARIMA (1,0,0) (0,1,1) ¹²	AR(1)	0.636269	< 2.2e-16 ***	Model Signifikan
	SMA(1)	-0.351624	3.07e-05 ***	
SARIMA (0,0,1) (0,1,1) ¹²	MA(1)	0.554331	< 2.2e-16 ***	Model Signifikan
	SMA(1)	-0.273727	0.000258 ***	
SARIMA (1,0,1) (0,1,1) ¹²	AR(1)	0.527702	9.392e-10 ***	Model Signifikan
	MA(1)	0.186948	0.04237 *	
	SMA(1)	-0.341915	4.872e-05 ***	
SARIMA (2,0,0) (0,1,1) ¹²	AR(1)	0.732802	< 2.2e-16 ***	Model Signifikan
	AR(2)	-0.156059	0.0248 *	
	SMA(1)	-0.333574	6.47e-05 ***	
SARIMA (0,0,2) (0,1,1) ¹²	MA(1)	0.664133	< 2.2e-16 ***	Model Signifikan
	MA(2)	0.354193	1.710e-07 ***	
	SMA(1)	-0.311501	5.336e-05 ***	

Berdasarkan hasil yang ditunjukkan pada Tabel 4, seluruh model SARIMA kandidat memiliki parameter yang signifikan dengan nilai *p-value* lebih kecil dari tingkat signifikansi 0,05. Hal ini berarti bahwa parameter-parameter yang terbentuk dalam model memberikan pengaruh secara nyata dalam menjelaskan pola data.

E. Pemilihan Model Terbaik

Kriteria pemilihan model terbaik mengacu pada nilai AIC terendah, dimana hal ini mengindikasikan model yang paling efisien dalam menyeimbangkan antara tingkat ketepatan model dan kompleksitas parameter.

Tabel 5. Nilai AIC Model SARIMA

Model	df	AIC
(1,0,0) (0,1,1) ¹²	3	4983.09
(0,0,1) (0,1,1) ¹²	3	5003.06
(1,0,1) (0,1,1) ¹²	4	4981.21
(2,0,0) (0,1,1) ¹²	4	4980.12
(0,0,2) (0,1,1) ¹²	4	4981.57

Berdasarkan Tabel 5, terlihat bahwa model SARIMA (2,0,0) (0,1,1)¹² mempunyai nilai AIC terendah yaitu 4980.12, dibandingkan dengan kandidat model lainnya. Hal ini menunjukkan bahwa model SARIMA (2,0,0) (0,1,1)¹² merupakan model terbaik karena paling optimal dalam menjelaskan pola data dengan kompleksitas parameter yang efisien.

F. Uji Diagnostik


1. Uji *White Noise*

Tabel 6. Uji Ljung-Box

X-squared	df	P-value
11.042	20	0.5712

Berdasarkan Tabel 6, hasil uji Ljung-Box menghasilkan *p-value* sebesar 0,5712 yang nilainya melebihi batas signifikansi 0,05. Ini berarti bahwa tidak terdapat autokorelasi yang signifikan pada residual hingga lag ke-20. Dengan demikian, residual model dapat dianggap bersifat *white noise* dan memenuhi asumsi independensi.

Plot diagnostik residual dari model SARIMA terbaik ditampilkan untuk memastikan bahwa residual memenuhi asumsi *white noise*. Pada plot terlihat bahwa residual menyebar acak di sekitar nol, tidak terdapat autokorelasi yang signifikan hingga beberapa lag pada plot ACF, serta distribusinya mendekati normal pada histogram residual. Dengan demikian, model yang dibangun telah memenuhi syarat untuk digunakan dalam melakukan peramalan, yang ditunjukkan Gambar 4.



Gambar 4. Plot Diagnostik Residual Model SARIMA

2. Uji Normalitas

Tabel 7. Uji Shapiro-Wilk

W	P-value
0.94599	6.147e-08


Dari Tabel 7, terlihat bahwa residual model tidak terdistribusi secara normal. Syarat kenormalan residual dipenuhi apabila nilai *P-value* melebihi 0,05. Meskipun demikian, kondisi ini tidak menjadi masalah mengingat berlakunya Teorema Limit Pusat (Central Limit Theorem/CLT) dalam teori probabilitas, yang memungkinkan data hasil olahan dianggap mendekati distribusi normal. Alasan utamanya adalah jumlah data sampel dalam penelitian ini mencapai 216 data bulanan, atau lebih dari 30, sehingga asumsi normalitas dapat diabaikan. Pernyataan ini didukung oleh pendapat Bowerman & Murphree, n.d (2017:334), seperti yang dikutip dalam (Yuliyanti & Arliani, 2022), yang menyatakan bahwa semakin besar ukuran sampel (*n*), distribusi rata-rata sampel akan semakin mendekati bentuk distribusi normal. Dengan demikian, model dapat diproses lebih lanjut ke tahap berikutnya.

G. Peramalan dengan Model Terbaik

Hasil peramalan yang dihasilkan dari model terbaik tersebut ditampilkan pada Tabel 8 berikut untuk melihat nilai prediksi untuk 24 periode kedepannya.

Tabel 8. Hasil Peramalan Produksi Kelapa Sawit Perkebunan Rakyat

No	Periode	Peramalan SARIMA
1	Januari 2024	397.981,7
2	Februari 2024	353.213,9
3	Maret 2024	376.588,4
4	April 2024	361.281,4
5	Mei 2024	431.776,7
6	Juni 2024	444.406,3
7	Juli 2024	462.204,2
8	Agustus 2024	470.554,2
9	September 2024	466.187,6
10	Oktober 2024	462.647,0
11	November 2024	440.969,0
12	Desember 2024	423.556,7
13	Januari 2025	400.395,8
14	Februari 2025	355.062,5
15	Maret 2025	377.566,3
16	April 2025	361.709,6
17	Mei 2025	431.937,9
18	Juni 2025	444.457,6
19	Juli 2025	462.216,6
20	Agustus 2025	470.555,3
21	September 2025	466.186,5
22	Oktober 2025	462.646,0
23	November 2025	440.968,4
24	Desember 2025	423.556,4



Gambar 5. Plot Peramalan Produksi Kelapa Sawit Perkebunan Rakyat

Berdasarkan peramalan hasil produksi kelapa sawit perkebunan rakyat di Provinsi Riau periode Januari 2024 hingga Desember 2025, diperoleh nilai prediksi yang relatif stabil dari bulan ke bulan, dengan kisaran produksi sekitar 350.000 hingga 470.000 ton. Pola musiman masih terlihat jelas, di mana puncak produksi diperkirakan terjadi pada Agustus-September dengan nilai sekitar 466.000 ton, sedangkan titik terendah diperkirakan pada Februari-Maret sekitar 353.000–355.000 ton.


H. Akurasi Peramalan

Tabel 9. Nilai Peramalan MAPE

Model	MAPE
(2,0,0) (0,1,1) ¹²	11.26644

Berdasarkan hasil evaluasi akurasi peramalan, model SARIMA (2,0,0) (0,1,1)¹² menghasilkan nilai MAPE sebesar 11,27%. Jika mengacu pada kriteria penilaian MAPE, nilai tersebut berada pada rentang 10%–20% yang termasuk dalam kategori baik. Dengan demikian, peramalan yang dihasilkan oleh model memiliki tingkat akurasi sebesar 88,73%, sehingga dapat dikatakan cukup andal untuk digunakan dalam memprediksi hasil produksi kelapa sawit perkebunan rakyat di Provinsi Riau.

Evaluasi akurasi model, yang tidak hanya bergantung pada nilai MAPE, juga memperhatikan kedekatan antara data observasi dengan nilai *fitted*, sebagaimana terlihat dalam plot pada Gambar 6.



Gambar 6. Perbandingan Plot Data Asli & Data Fitted Model SARIMA

Berdasarkan Gambar 6 terlihat bahwa pola *fitted values* (garis merah putus-putus) mengikuti pola data asli (garis biru) dengan cukup baik, meskipun terdapat beberapa deviasi pada periode tertentu. Hal ini menunjukkan bahwa model mampu merepresentasikan tren dan pola musiman produksi kelapa sawit dengan cukup akurat, meskipun fluktuasi ekstrim pada beberapa bulan belum sepenuhnya tertangkap dengan baik oleh model.

IV. KESIMPULAN

Berdasarkan hasil dari penelitian ini, dapat disimpulkan bahwa pendekatan SARIMA terbukti efektif untuk meramalkan data produksi kelapa sawit dari perkebunan rakyat di Provinsi Riau. Setelah mengevaluasi beberapa model, teridentifikasi bahwa spesifikasi SARIMA (2,0,0) (0,1,1)¹² merupakan model yang paling optimal, dengan nilai AIC sebesar 4980,12 dan MAPE sebesar 11,27%. Berdasarkan nilai MAPE tersebut, dapat disimpulkan model ini memiliki akurasi yang tergolong baik dalam menggambarkan pola musiman serta tren produksi kelapa sawit dalam jangka panjang. Hasil peramalan menunjukkan bahwa pola produksi cenderung stabil dengan produksi terbanyak pada bulan Agustus-September dan produksi terendah pada Februari-Maret setiap tahunnya.

DAFTAR PUSTAKA

Arunika, K. R., Joni, L., & Dewi, E. (2021). *PERBANDINGAN MODEL SARIMA , EXPONENTIAL SMOOTHING*,

DAN XGBOOST UNTUK PREDIKSI. 13(3).

- Febiola, A., Dewi, A., Fazarin, F. M., Ramadhani, F., Khaffi, M. A., Akbar, R., & Dalimunthe, D. Y. (2024). Perbandingan Metode ARIMA dan SARIMA Dalam Peramalan Jumlah Penumpang Bandara Provinsi Kepulauan Bangka Belitung. *Jambura Journal of Mathematics*, 6(2), 160–168. <https://doi.org/10.37905/jjom.v6i2.25081>
- Junaedi, L., Damastuti, N., & Widodo, A. (2025). Penerapan Metode Seasonal ARIMA (SARIMA) untuk Peramalan Penjualan Barang dengan Pola Musiman Tahunan. *JISEM Jurnal Program Studi Informatika Universitas Katolik Widya Mandala Surabaya*, 01(1), 38–48. <https://doi.org/10.33508/jisem.v1i01.740338>
- Nurfitri Imro'ah, N. S. R. A. S. M. (2019). Prediksi Produksi Kelapa Sawit Di Ptpn Xiii Dengan Additive Outlier Pada Model Seasonal Autoregressive Integrated Moving Average (Sarima). *Bimaster : Buletin Ilmiah Matematika, Statistika Dan Terapannya*, 8(4), 875–882. <https://doi.org/10.26418/bbimst.v8i4.36562>
- Redaksi, I. (2024). *Luas Perkebunan Sawit di Riau capai 2,87 juta Ha Perkebunan Rakyat Mendominasi*. <https://www.infosawit.com/2024/01/23/luas-perkebunan-sawit-di-riau-capai-287-juta-ha-perkebunan-rakyat-mendominasi/>
- Ruhat, D., Masrulloh, E. S., & Azis, F. (2022). Forecasting Data Time Series Berpola Musiman Menggunakan Model SARIMA (Studi Kasus: Sungai Cipeles-Warungpeti). *Jurnal Riset Matematika Dan Sains Terapan*, 39(1), 39–50.
- Yuliyanti, R., & Arliani, E. (2022). Peramalan jumlah penduduk menggunakan model arima Forecasting the number of population using the arima. *Jurnal Kajian Dan Terapan Matematika*, 8(2), 114–128. <http://journal.student.uny.ac.id/ojs/index.php/jktm:>