

Implementasi Model SARIMA Untuk Memprediksi Produksi Minyak Kelapa Sawit

Luis Fernandes Tokan¹, Arief Hermawan²

^{1,2}Informatika, Fakultas Sains dan Teknologi, Universitas Teknologi Yogyakarta

¹fernandeztokan@gmail.com *, ²ariefdb@uty.ac.id

Abstract

Palm oil is a vital commodity in the plantation industry, with a significant impact on the global economy. The main challenges in production planning and market analysis stem from insufficient preparation. Therefore, this research aims to implement the SARIMA (Seasonal Autoregressive Integrated Moving Average) model to predict palm oil production for the period 2022-2026. Data is sourced from the Agricultural Statistics Book of the Directorate General of Plantation, Ministry of Agriculture. The analysis results reveal that the SARIMA model with parameters (1,0,1)(1,0,0)12 yielded the best outcomes, with a Mean Absolute Percentage Error (MAPE) of 5.54%. These results show that the SARIMA model can predict palm oil production with good accuracy based on historical data. This prediction system is expected to make a significant contribution in reducing uncertainty in palm oil production, increasing production efficiency in reducing the resulting environmental impacts, as well as assisting the government and related organizations in conducting better planning in paying attention to high quality production.

Keywords: Sarima, Palm Oil, Forecasting, Time Series

Abstrak

Minyak kelapa sawit adalah komoditas penting dalam industri perkebunan dengan dampak besar pada ekonomi global. Tantangan utama dalam perencanaan produksi dan analisis pasar adalah kurangnya persiapan yang memadai. Oleh karena itu, penelitian ini bertujuan untuk menerapkan model SARIMA (*Seasonal Autoregressive Integrated Moving Average*) dalam memprediksi produksi minyak kelapa sawit untuk periode 2022-2026. Data diperoleh dari Buku Statistik Perkebunan DITJENBUN Pertanian. Hasil analisis menunjukkan bahwa model SARIMA dengan parameter (1,0,1)(1,0,0)12 memberikan hasil terbaik dengan tingkat *Mean Absolute Percentage Error* (MAPE) sebesar 5,54%. Hasil ini menunjukkan bahwa model SARIMA dapat memprediksi produksi minyak kelapa sawit dengan akurasi yang baik berdasarkan data historis. Sistem prediksi ini diharapkan memberikan kontribusi signifikan dalam mengurangi ketidakpastian dalam produksi minyak kelapa sawit, meningkatkan efisiensi produksi dalam mengurangi dampak lingkungan yang dihasilkan, serta membantu pemerintah dan organisasi terkait dalam melakukan perencanaan yang lebih baik dalam memperhatikan kualitas produksi yang tinggi.

Kata kunci: Sarima, Minyak Kelapa Sawit, Peramalan, Deret Waktu

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International License

1. Pendahuluan

Kelapa sawit (*Elaeis guineensis*) merupakan tanaman penghasil minyak nabati terbesar dan paling produktif jika dibandingkan dengan tanaman yang menghasilkan minyak lainnya [1]. Kelapa sawit menjadi tumbuhan perkebunan yang berada pada posisi penting di sektor perkebunan dan pertanian karena menghasilkan nilai ekonomi terbesar per hektarnya di dunia [2]. Kelapa sawit memiliki peran penting dalam perekonomian global, terutama sebagai penyumbang devisa [3] dan pencipta lapangan kerja bagi masyarakat.

Kelapa sawit berasal dari Afrika Barat dan dapat tumbuh dan berproduksi dengan baik di Indonesia [4]. Mengingat curah hujan dan suhu tropis di Indonesia, tanaman kelapa sawit ini cocok dibudidayakan di Indonesia [5]. Produksi kelapa sawit di Indonesia mencapai 26,57 ton pada tahun 2022 dengan luas kebun 8,51 juta hektar [6]. Minyak kelapa sawit merupakan produk utama yang dihasilkan dari buah kelapa sawit. Minyak ini digunakan dalam berbagai industri, seperti makanan, kosmetik, dan bahan bakar biodiesel [7].

Indonesia merupakan salah satu negara dengan penghasil dan eksportir minyak sawit terbesar di dunia, dengan produksi lebih dari 18 juta ton per tahun. Pangsa produksi CPO (*Crude Palm Oil*) Indonesia mencapai 53,4% dari total CPO dunia [8].

Terdapat beberapa masalah terkait produksi minyak kelapa sawit. Pertama, produksi minyak kelapa sawit di Indonesia masih mengalami fluktuasi. Tingkat harga minyak kelapa sawit juga mempengaruhi produksi dan kinerja perdagangan kelapa sawit Indonesia [8]. Produksi minyak kelapa sawit sering mengalami fluktuasi yang disebabkan oleh faktor-faktor seperti iklim [9], penyakit tanaman [10], dan perubahan pola musim [11]. Kedua, produksi minyak kelapa sawit menghasilkan limbah cair yang dapat mengandung polutan seperti *biochemical oxygen demand* (BOD), *total suspended solids* (TSS), minyak, dan lemak [12]. Ketiga, masalah pasokan minyak kelapa sawit di Indonesia untuk biodiesel yaitu pasokan CPO yang tidak memenuhi pedoman perusahaan mengenai kualitas yang disepakati dengan konsumen, seperti tingginya tingkat kadar asam lemak bebas, kadar air,

dan kadar kotoran [9]. Oleh karena itu, penting untuk mengetahui tren produksi minyak kelapa sawit Indonesia di masa yang akan datang agar dapat mengurangi ketidakpastian dalam produksi minyak kelapa sawit, meningkatkan efisiensi produksi dalam mengurangi dampak lingkungan yang dihasilkan, serta pemerintah dan organisasi terkait dapat melakukan perencanaan yang lebih baik dalam memperhatikan kualitas produksi yang tinggi dan memenuhi standar kesepakatan yang telah disepakati.

Sebelumnya, penelitian lain yang telah menggunakan model SARIMA sudah cukup banyak diantaranya dengan judul Prediksi Produksi Bawang Merah Di Kabupaten Nganjuk Dengan Metode *Seasonal ARIMA* (SARIMA). Data penelitian yang digunakan berasal dari *website* BPS Kabupaten Nganjuk dari bulan Januari 2017 – Desember 2020. Dengan mengambil nilai rata-rata perbulan dari 20 kecamatan di Nganjuk. Hasil penelitian ini adalah model SARIMA cukup efektif dalam pembentukan model terbaik untuk prediksi, yaitu model SARIMA (3,0,2)(2,1,2)₁₂ yang memiliki nilai MAPE sebesar 2,01% [13]. Peneliti lain, dengan judul Peramalan dengan Metode Pemulusan Eksponensial *Holt-Winter* dan SARIMA (Studi Kasus: Jumlah Produksi Ikan (Ton) di kota Sibolga Tahun 2000-2017). Data yang digunakan dalam penelitian ini adalah data Jumlah produksi ikan (ton) per-kuartal di kota Sibolga tahun 2000-2017 yang diperoleh dari BPS Kota Sibolga. Dengan model SARIMA (0,1,1)(0,1,1)₄ menghasilkan tingkat kesalahan peramalan MAE, RMSE, MAPE masing-masing 693.11, 903033.90, 5.92%. Hasil akhir dari penelitian yang diketahui bahwa peramalan jumlah produksi ikan dengan metode SARIMA lebih baik daripada metode eksponensial *Holt-Winter* [14].

Peneliti lain dengan penelitian memprediksi produksi minyak kelapa sawit. Namun, dengan algoritma yang berbeda salah satunya yaitu dengan menggunakan Metode *Holt-Winters Exponential Smoothing* (Studi Kasus: PT. Sinar Gunung Sawit Raya). Data yang digunakan dalam penelitian ini adalah data Jumlah produksi minyak kelapa sawit di PT.SGSR bulan Januari 2022 - Desember 2022 yang diperoleh dari PT. Sinar Gunung Sawit Raya(SGSR) tahun 2022. Dengan menghasilkan parameter yang dipilih secara *trial* dan *error* yaitu =0,84, -0,09 dan -0,83 dengan memperoleh nilai kesalahan MAPE terbaik yaitu model aditif sebesar 2,11% yang berarti metode *Holt-Winters Exponential Smoothing* dengan model aditif memiliki nilai akurasi yang lebih baik dibandingkan dengan multiplikatifnya dalam meramalkan Jumlah produksi minyak kelapa sawit di PT. Sinar Gunung Sawit Raya [15]. Peneliti lainnya yang juga melakukan penelitian terkait dengan judul Peramalan Produksi *Crude Palm Oil* Dengan Algoritma Backpropagation Neural Network. Data yang digunakan adalah data produksi CPO di PT. X dari bulan Januari 2019 – April 2021. Dengan model arsitektur terbaik menggunakan empat neuron *hidden layer*, dengan fungsi pembelajaran

trainlm, fungsi aktivasi sigmoid, epoch 5000, dan *learning rate* 0,1 menghasilkan nilai error (MSE) terbaik 0,00054 pada pelatihan dan 0,00372 pada proses pengujian [16].

Berdasarkan penjelasan latar belakang diatas, tujuan dari penelitian ini adalah mengimplementasikan Model SARIMA (*Seasonal Autoregressive Integrated Moving Average*) untuk memprediksi produksi minyak kelapa sawit. Dikarenakan, model ini cocok untuk data yang memiliki pola musiman, seperti pada data produksi minyak kelapa sawit yang sering mengalami fluktuasi musiman. Dengan menggunakan data produksi minyak kelapa sawit di Indonesia, penelitian ini diharapkan dapat memberikan solusi dalam mengatasi masalah di industri minyak kelapa sawit Indonesia. Kontribusi utama riset ini adalah pengembangan metode peramalan yang efektif dengan Model SARIMA yang jarang digunakan dalam konteks produksi minyak kelapa sawit di Indonesia.

Perbedaan utama antara penelitian ini dan penelitian sebelumnya adalah penggunaan data produksi yang mencakup periode waktu yang lebih panjang. Data yang lebih luas ini dapat memberikan wawasan yang lebih mendalam tentang variabilitas dan pola produksi minyak kelapa sawit, yang dapat memungkinkan pemangku kepentingan lebih baik dalam menyusun strategi untuk melakukan keputusan yang lebih efektif.

Oleh karena itu, diharapkan penelitian ini dapat memberikan kontribusi penting dalam mengatasi tantangan yang ada dalam industri minyak kelapa sawit di Indonesia dan meningkatkan praktik-praktik yang ada di sektor ini. Bahasa pemrograman yang digunakan adalah *python* dengan bantuan *google colab*.

2. Metode Penelitian

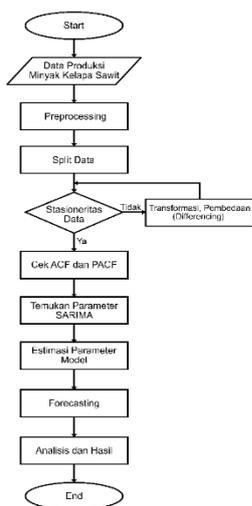
2.1 SARIMA (*Seasonal Autoregressive Integrated Moving Average*)

Metode SARIMA (*Seasonal Autoregressive Integrated Moving Average*) merupakan metode dalam memproses data deret waktu untuk analisis dan peramalan dengan pola musiman. Metode ini merupakan pengembangan dari model ARIMA (*Autoregressive Integrated Moving Average*) yang dapat mengatasi data dengan pola musiman yang kompleks [17]. Metode ini terdiri dari beberapa tahap yaitu identifikasi, estimasi parameter, pemeriksaan diagnostik dan prediksi menggunakan model SARIMA (p,d,q)(P,D,Q)_S [18].

2.2 Alur Penelitian

Metode yang digunakan dalam penelitian ini melibatkan analisis literatur untuk memahami konsep-konsep yang relevan dengan topik penelitian yang diambil. Selain itu, data yang digunakan adalah dataset statistik untuk melakukan analisis data yang lebih lanjut.

Selanjutnya, sistem dikembangkan dengan menguraikan tahap-tahapannya secara terperinci melalui pembuatan sebuah bagan alir/flowchart. Bagan alir ini akan menggambarkan alur kerja sistem yang melibatkan berbagai tahapan yang akan dirincikan dari tahap awal hingga tahap akhir penelitian ini. Dengan menggunakan bagan alir ini, memudahkan pemahaman tentang proses yang dilakukan dalam penelitian ini, dan juga memastikan setiap langkahnya dapat terperinci secara jelas dan terstruktur, diagram bagan alir dapat dilihat pada Gambar 1.



Gambar 1. Diagram Alir Proses Penelitian

Dengan memperhatikan Gambar 1, maka sistem peramalan dengan metode SARIMA dapat digambarkan secara khusus, sebagai berikut :

1. Data Produksi Minyak Kelapa Sawit

Melakukan input data dengan dua atribut yang digunakan, yaitu Tahun dan Total Produksi. Data yang digunakan adalah data *time series* produksi minyak kelapa sawit dari tahun 1980 sampai 2021 yaitu sebanyak 42 baris data yang diambil dari sumber Buku Statistik Perkebunan DITJENBUN Pertanian: <https://ditjenbun.pertanian.go.id/template/uploads/2022/08/STATISTIK-UNGGULAN-2020-2022.pdf>.

2. Preprocessing

Bagian ini merencanakan data mentah yang nantinya akan digunakan sebagai informasi untuk menjadi masukan agar model menjadi yang terbaik.

3. Split data

Proses ini bertujuan membagi data menjadi dua bagian yaitu, *train data* dan *test data*.

4. Stasioneritas Data

Untuk melakukan uji stasioneritas data dapat dilakukan dengan menggunakan dua metode pengujian yaitu *Augmented Dickey-Fuller* (ADF) dan pengujian *Kwiatkowski-Phillips-Schmidt-Shin* (KPSS). Jika data tidak stasioner maka perlu distasionerkan dengan proses transformasi atau pembedaan (*differencing*). Data

yang stasioner menurut pengujian ADF jika p-value lebih kecil dari nilai signifikansi yang ditentukan (0.05), dan stasioner menurut pengujian KPSS jika p-value lebih besar dari nilai signifikansi (0.05).

5. Cek ACF dan PACF

Ketika data sudah stasioner atau diperbaiki, maka *kenali* pola musiman dengan memperhatikan plot ACF (*Autocorrelation Function*) dan plot PACF (*Partial Autocorrelation Function*) untuk memutuskan orde model awal.

6. Temukan Parameter SARIMA

Parameter model SARIMA yang optimal untuk data produksi minyak kelapa perlu ditentukan. Ini melibatkan analisis ACF (*Autocorrelation Function*) serta PACF (*Partial Autocorrelation Function*) untuk mengidentifikasi orde model ARIMA dan SARIMA yang sesuai.

7. Estimasi Parameter Model

Setelah parameter model SARIMA ditentukan, langkah selanjutnya adalah mengestimasi parameter tersebut dari data historis. Estimasi ini dilakukan menggunakan metode statistik yang akan menghasilkan model SARIMA yang sesuai dengan data.

8. Forecasting

Dengan model SARIMA yang telah diestimasi, kemudian lakukan peramalan produksi minyak kelapa sawit untuk masa depan. Ini memungkinkan untuk menghasilkan prediksi produksi minyak kelapa sawit untuk periode 2022-2026. Model SARIMA untuk melakukan peramalan terdapat persamaan yang digunakan, yaitu (p,d,q) dan musiman (P,D,Q)s dengan menggunakan *mean* sebagai referensi. Pada persamaan tersebut, p, d, q, P, D, dan Q merupakan bilangan bulat yang menentukan orde dan karakteristik model, sedangkan (s) merujuk pada periodeisitas data. Untuk persamaan perhatikan pada berikut ini (1).

$$\phi_p(B)\phi_p(B^S)(1-B)^d(1-B^S)^D X_t = \theta_q(B)\theta_q(B^S)\varepsilon_t \quad (1)$$

Keterangan:

- X_t = data deret waktu periode T.
- $\phi_p(B)$ = AR non-musiman $AR(p)$
- $\theta_q(B)$ = MA non-musiman $MA(q)$
- $\phi_p(B^S)$ = AR musiman $AR(P)$
- $\theta_q(B^S)$ = MA musiman $MA(q)$
- $(1-B^S)^D$ = operator pembeda musiman periode S
- $(1-B)^d$ = operator pembeda non musiman
- ε_t = *white noise*

9. Analisis dan Hasil

Tahap akhir dari penelitian ini melibatkan analisis hasil peramalan dan implementasi sistem. Hasil peramalan akan disajikan dalam bentuk grafik untuk memvisualisasikan prediksi produksi minyak kelapa

sawit di Indonesia untuk masa yang akan datang. Selanjutnya, dilakukan pengujian sistem dengan menggunakan metrik *Mean Absolute Percentage Error* (MAPE). MAPE digunakan untuk mengetahui presentase *error* pada hasil peramalan [19] dan menganalisis sejauh mana sistem telah berjalan dengan baik dalam memprediksi produksi minyak kelapa sawit. MAPE dapat dihitung dengan persamaan (2).

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{(A_t - F_t)}{A_t} \right| 100}{n} \quad (2)$$

Keterangan:

- A_t = nilai aktual
- F_t = nilai *forecast*
- n = total data

3. Hasil dan Pembahasan

Penerapan Algoritma SARIMA dimaksudkan untuk memprediksi produksi minyak kelapa sawit di tahun yang akan datang. Pada penelitian ini dilakukan prediksi pada 5 tahun kedepan yaitu periode 2022-2026.

3.1 Data Produksi Minyak Kelapa Sawit

Tahap awal adalah pengumpulan data, berisi 42 baris data.

No	Tahun	Total Produksi
1	1980-12-31	72.1172
2	1981-12-31	800.060
3	1982-12-31	886.820
4	1983-12-31	982.987
5	1984-12-31	1.147.190
6	1985-12-31	1.243.430
7	1986-12-31	1.350.729
8	1987-12-31	1.506.055
9	1988-12-31	1.713.335
10	1989-12-31	1.964.954
11	1990-12-31	2.412.612
12	1991-12-31	2.657.600
13	1992-12-31	3.266.250
14	1993-12-31	3.421.449
15	1994-12-31	4.008.062
16	1995-12-31	4.479.670
17	1996-12-31	4.898.658
18	1997-12-31	5.448.508
19	1998-12-31	5.930.415
20	1999-12-31	6.455.590
21	2000-12-31	7.000.508
22	2001-12-31	8.396.472
23	2002-12-31	9.622.345
24	2003-12-31	10.440.834
25	2004-12-31	10.830.389
26	2005-12-31	11.861.615
27	2006-12-31	17.350.848
28	2007-12-31	17.664.725
29	2008-12-31	17.539.788
30	2009-12-31	19.324.293
31	2010-12-31	21.958.120
32	2011-12-31	23.096.541
33	2012-12-31	26.015.518
34	2013-12-31	27.782.004
35	2014-12-31	29.278.189
36	2015-12-31	31.070.015
37	2016-12-31	31.730.961
38	2017-12-31	37.965.224
39	2018-12-31	42.883.631
40	2019-12-31	47.120.247
41	2020-12-31	45.741.845
42	2021-12-31	45.121.480

Gambar 2. Dataset Produksi Minyak Kelapa Sawit

Gambar 2 menjelaskan bahwa terdapat 42 tahun produksi minyak kelapa sawit dari tahun 1980-2021, dataset dengan memiliki format *.csv.

3.2 Preprocessing

Pra-pemrosesan data adalah langkah penting mempersiapkan data sebelum dianalisis atau pemodelan. Pada tahap ini dilakukan *cleaning* untuk mengatasi masalah (*missing value*). Selanjutnya, pada tahap ini nama atribut diubah untuk memudahkan dalam proses penelitian dengan nama atribut yang lebih mudah(pendek). Tipe data Total Produksi diubah kedalam tipe data yang sesuai yaitu menjadi tipe data *datetime*. Tahun sebagai indeks untuk pengindeksan data dalam *DataFrame*. Berikut adalah contoh hasil dari *preprocessing* dapat dilihat pada Tabel 1 dibawah ini.

Tabel 1. Contoh Hasil Data *Preprocessing*

Tahun	Total
1980-12-31	721172.0
1981-12-31	800060.0
1982-12-31	886820.0
1983-12-31	982987.0
1984-12-31	1147190.0

Tabel 1 di atas merupakan contoh hasil proses *preprocessing*. Tabel tersebut, terdapat dua atribut "Tahun" dengan tipe data *datetime* dan "Total" tipe datanya *float64*.

3.3 Split Data

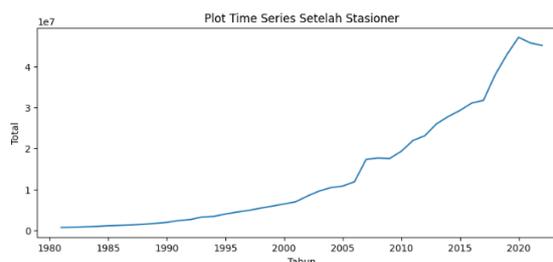
Data dibagi menjadi dua set yang berbeda: satu digunakan untuk melatih model (*train data*), sementara yang lainnya digunakan untuk menguji kinerja model (*test data*). Set pelatihan terdiri dari 37 baris data yang mencakup periode tahun 1980 hingga 2016, sedangkan set pengujian terdiri dari 5 baris data yang mencakup periode tahun 2017 hingga 2021. Berikut ditampilkan dengan tabel pembagian dataset pada Tabel 2 dibawah ini.

Tabel 2. Pembagian Dataset

Data	Rasio	Jumlah Data
Data Latih	88%	37
Data Uji	12%	5

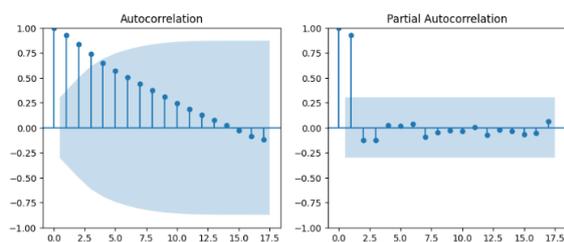
3.4 Stasioneritas Data

Setelah tahap *split data* selesai, langkah selanjutnya adalah membuat plot deret waktu untuk memvisualisasikan data dalam bentuk sekuensi waktu. Analisis data *time series* ini membantu dalam memahami pola, tren, serta fluktuasi yang terjadi dalam data seiring berjalannya waktu. Hasil dari visualisasi ini dapat ditemukan pada Gambar 3.



Gambar 3. Plot Produksi Minyak Kelapa Sawit (Ton)

Pada tahap ini dilakukan proses pengujian stasioneritas menggunakan dua metode yang berbeda, yaitu pengujian *Augmented Dickey-Fuller* (ADF) dan pengujian *Kwiatkowski-Phillips-Schmidt-Shin* (KPSS). Hasil pengujian ADF menunjukkan nilai p-value sebesar 1.0, sementara hasil pengujian KPSS menunjukkan p-value sebesar 0.1. Dalam hal ini, hasil pengujian p-value ADF lebih besar dari nilai signifikansi $1.0 > 0.05$. Berdasarkan hasil tersebut, dapat disimpulkan bahwa data tidak stasioner menurut pengujian ADF, tetapi stasioner menurut pengujian KPSS. Hasil ini menunjukkan bahwa data mungkin memiliki karakteristik stasioneritas tergantung pada metode pengujian yang digunakan. Selanjutnya, telah ditampilkan plot ACF (*Autocorrelation Function*) dan plot PACF (*Partial Autocorrelation Function*) untuk data yang tidak stasioner dalam gambar 4.

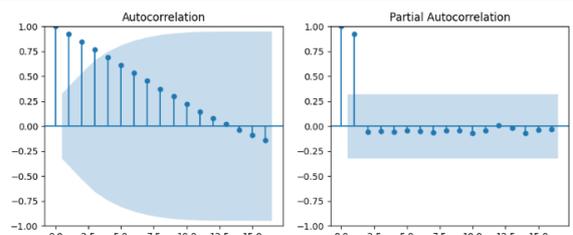


Gambar 4. Plot ACF dan PACF Data Tidak Stasioner

Dikarenakan data awalnya tidak stasioner, maka yang perlu dilakukan adalah menjalankan proses transformasi atau differensiasi (*differencing*) untuk mencapai stasioneritas. Pada data ini hanya dilakukan proses transformasi logaritma pertama yang menghasilkan data yang telah stasioner yaitu dengan nilai p-value 0.008 dalam uji ADF dan nilai p-value 0.1 dalam uji KPSS. Dalam konteks ini, hasil pengujian p-value ADF lebih kecil dari nilai signifikansi yaitu $0.008 < 0.05$ yang berarti stasioner menurut pengujian ADF, dan hasil pengujian KPSS lebih besar dari nilai signifikansi yaitu $0.1 > 0.05$ yang berarti stasioner menurut pengujian KPSS. Kedua tes menyimpulkan bahwa data yang diberikan adalah stasioner maka data disimpulkan telah mencapai tingkat stasioner. Hasil pengujian menunjukkan konsistensi antara ADF dan KPSS yang memberikan kepercayaan lebih besar dalam menyimpulkan bahwa data tersebut stasioner.

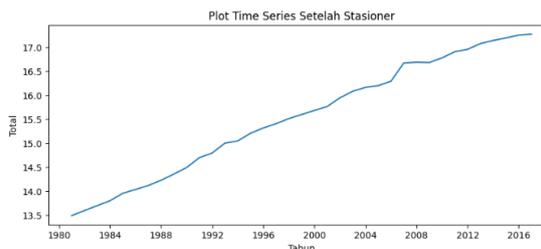
3.5 Cek ACF dan PACF

Setelah stasioner, kenali pola musiman dengan memperhatikan plot ACF (*Autocorrelation Function*) dan plot PACF (*Partial Autocorrelation Function*). Akan ditampilkan hasil plot ACF dan PACF, terlihat plot *autocorrelation* dan *partial correlation* menunjukkan bahwa dominan korelasi berada dalam interval kepercayaan, yang menunjukkan stasioneritas. Maka data telah memenuhi stasioneritas dan dapat dilanjutkan pada proses selanjutnya yaitu penentuan parameter. Ditampilkan pada Gambar 5.



Gambar 5. Plot ACF dan PACF

Berikut ditampilkan juga visual *plot time series* dari data yang telah distasionerkan pada Gambar 6 dibawah ini.



Gambar 6. Plot Data Setelah Stasioner

3.6 Temukan Parameter SARIMA

Berdasarkan data pada Gambar 5, dikarenakan data untuk komponen non-musiman tidak dilakukan differensiasi pertama atau bahkan kedua maka orde differensiasi $d = 0$. Pada plot ACF non-musiman lag ke-1, ke-2, ke-3, dan ke-4 menunjukkan *cut off* sehingga dapat mencoba $q = 0, 1, \text{ atau } 2$ untuk itu sementara MA adalah $q = 1$. Plot PACF non-musiman pada lag ke-1 dan ke-2 menunjukkan *cut off* melewati interval, dapat mencoba $p = 1$ atau 2 maka untuk sementara nilai AR adalah $p = 2$. Selanjutnya, $D = 0$ karena tidak melakukan differensiasi musiman. Plot ACF musiman dengan tidak adanya penurunan signifikan dalam lag musiman maka SMA adalah $Q = 0$. Plot PACF musiman terdapat *cut off* di lag ke-1, dan ke-2 yang signifikan turun pada lag selanjutnya maka SAR adalah $P = 2$ sehingga identifikasi model sementara SARIMA adalah $(1,0,1)(2,0,0)_{12}$. Identifikasi model sementara dengan memeriksa plot ACF dan PACF digunakan sebagai petunjuk awal mengenai orde awal model. Model sementara ini digunakan sebagai panduan untuk parameter model SARIMA yang optimal. Untuk mendapatkan model terbaik akan dilakukan berbagai kombinasi parameter (*auto_arima*) dan memilih model dengan kriteria informasi terbaik (BIC) yang akan dilakukan pada proses selanjutnya.

3.7 Estimasi Parameter Model

Tahap selanjutnya adalah memilih model yang tepat berdasarkan data historis dan bantuan model sementara dengan komponen yang telah didapatkan sebelumnya. Penelitian ini menggunakan *auto_arima* untuk mengevaluasi berbagai kombinasi parameter dengan efisien dan kriteria informasi seperti AIC (*Akaike Information Criterion*), BIC (*Bayesian Information Criterion*), atau HQIC (*Hannan-Quinn Information Criterion*) untuk memilih model terbaik dengan kriteria

informasi yang terbaik. Dalam penelitian ini, BIC (*Bayesian Information Criterion*), sebagai fokusnya untuk menentukan pilihan terbaik karena jumlah data yang relatif kecil (hanya 42 baris data). Pemilihan model yang terlalu kompleks dalam kasus dataset yang kecil dapat mengakibatkan *overfitting*. Oleh karena itu, BIC menjadi pilihan yang baik karena akan memberikan penalti yang lebih tinggi terhadap kompleksitas model. Berikut adalah hasil model dengan nilai kriteria informasinya yang tidak hanya menampilkan BIC sebagai fokus, namun juga menampilkan nilai AIC dan HQIC sebagai perbandingan yang ditampilkan pada Tabel 3.

Tabel 3. Model SARIMA

Model	BIC	AIC	HQIC
(p,d,q)(P,D,Q)s			
SARIMA (2,0,2)(0,0,1) ₁₂	-40.454	-51.730	-47.755
(2,0,2)(0,0,0) ₁₂	-35.272	-44.931	-41.530
(1,0,2)(0,0,0) ₁₂	-42.663	-48.285	-46.013
(1,0,1)(0,0,1) ₁₂	-41.940	-53.412	-51.140
(1,0,1)(2,0,0) ₁₂	-47.928	-55.980	-53.140
(1,0,1)(1,0,0) ₁₂	-51.448	-57.891	-55.620

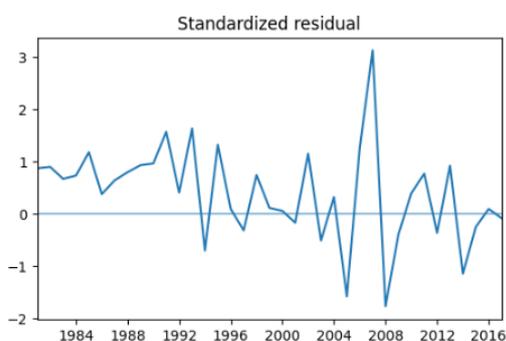
Berdasarkan model SARIMA pada Tabel 3 didapatkan model terbaik yaitu (1,0,1)(1,0,0)₁₂ dengan nilai BIC - 51.448, AIC -57.891, dan HQIC -55.620. Dengan model yang terbaik maka estimasi parameter adalah sesuai dengan Tabel 4 sebagai berikut dibawah ini.

Tabel 4. Hasil Model SARIMA (1,0,1)(1,0,0)₁₂

Parameter	Koefisien	Koefisien <i>Standard Error</i>
AR1	0.9997	0.002
MA1	0.3050	0.156
SAR1	0.7289	0.162
Sigma2	0.0058	0.001

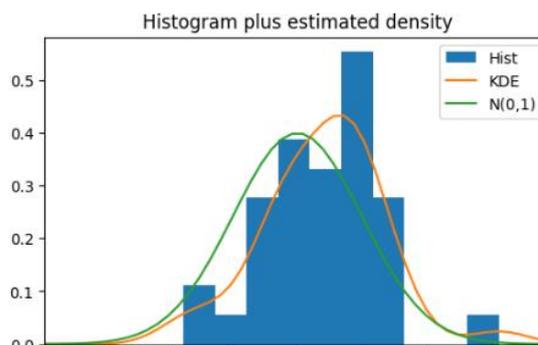
Berdasarkan pada Tabel 4 diatas ditampilkan koefisien dengan nilai terbaik beserta *standar nilai error* dari model SARIMA (1,0,1)(1,0,0)₁₂.

Selain menampilkan koefisien model pada Tabel diatas, ditampilkan juga plot-diagnostik dari proses analisis model statistika, terkhusus pada model *time series* untuk memudahkan dalam mengetahui sejauh mana model sesuai dengan data. Plot yang dihasilkan dalam proses ini adalah *Standardized Residuals vs Fitted Values*, *Histogram plus Estimated Density*, *Normal Q-Q Plot*, dan *Correlogram of Residuals*.



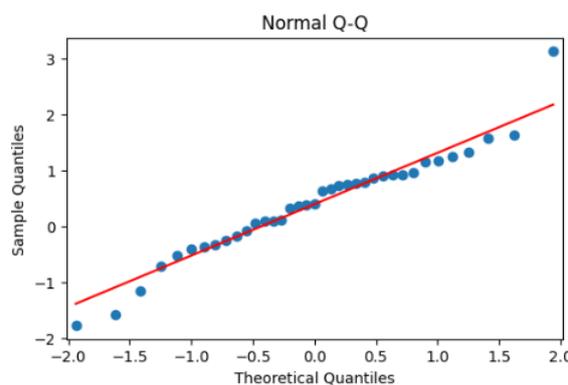
Gambar 7. Plot *Standardized Residual*

Gambar 7 diatas, adalah grafik evaluasi pola tertentu pada model.



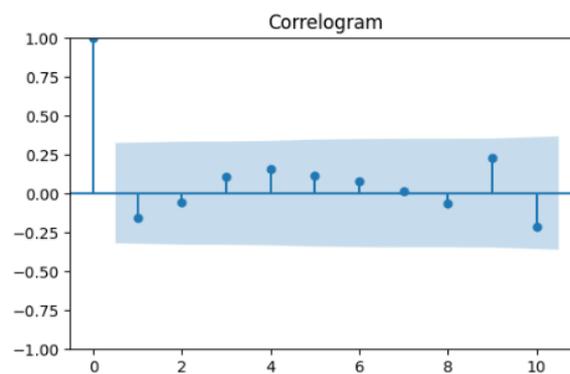
Gambar 8. Plot *Histogram plus Estimated Density*

Gambar 8 diatas, adalah grafik yang menampilkan visual sebaran frekuensi dari residu.



Gambar 9. Plot *Normal Q-Q*

Gambar 9 diatas, adalah plot untuk membandingkan seberapa cocok distribusi residu (titik-titik) menyerupai distribusi normal standar(garis). Selanjutnya pada gambar dibawah ini merupakan plot *correlogram* untuk menampilkan korelasi antara nilai residu tertentu dengan nilai yang sebelumnya (*lag*). Berikut dapat ditampilkan pada Gambar 10 dibawah ini.



Gambar 10. Plot *Correlogram*

3.8 Forecasting

Model yang telah didapatkan digunakan untuk peramalan. Lakukan perbandingan hasil nilai prediksi dengan nilai *actual* pada data *time series* untuk melihat hasil peramalan dari model yang telah didapat. Grafik *forecasting* dapat dilihat pada Gambar 11. Untuk mengukur keakuratan hasil prediksi dapat menggunakan proses pengujian MAPE. Dengan

menggunakan MAPE akan memberikan hasil yang mudah diinterpretasikan karena dinyatakan dalam bentuk presentasi, dan lebih mudah dipahami.



Gambar 11. Hasil forecasting

Peramalan diproses dalam jangka periode tahunan dikarenakan data yang digunakan adalah data tahunan. Pada penelitian ini dilakukan peramalan/prediksi untuk lima tahun kedepan yaitu dari tahun 2022 sampai 2026. Dapat dilihat pada Tabel 5 dibawah ini untuk hasil yang didapatkan.

Tabel 5. Hasil Forecasting

Model	Tahun yang diprediksi	Hasil
(1,0,1)(1,0,0) ₁₂	2022	17.621314
	2023	17.627000
	2024	17.687084
	2025	17.663974
	2026	17.666248

3.9 Analisis dan Hasil

Tahap berikutnya dalam penelitian ini adalah menganalisis hasil prediksi yang mencakup pengujian pada sistem dengan memakai metrik MAPE (*Mean Absolute Percentage Error*). Hasil pengujian menggunakan model yang telah dibangun menunjukkan bahwa setelah melakukan peramalan atau prediksi, rata-rata kesalahan dapat dilihat pada Tabel 6.

Tabel 6. Perhitungan MAPE

Model	MAPE
(1,0,1)(1,0,0) ₁₂	5.54%

4. Kesimpulan

Dalam penelitian ini, berhasil mengimplementasikan model SARIMA untuk memprediksi produksi minyak kelapa sawit di Indonesia untuk periode 2022-2026. Hasil peramalan menunjukkan tingkat kesalahan MAPE sebesar 5.54%, dengan model terbaik (1,0,1)(1,0,0)₁₂. Dapat disimpulkan bahwa model SARIMA memiliki kemampuan peramalan yang baik dalam konteks industri sektor pertanian terkhusus minyak kelapa sawit di Indonesia.

Implikasi dari penelitian ini adalah hasil peramalan yang akurat dapat mendukung perencanaan produksi yang lebih efisien, pengelolaan sumber daya yang lebih baik, dan pengambilan keputusan yang lebih baik dalam pengembangan industri minyak kelapa sawit. Hasil ini juga dapat membantu mengurangi risiko dan meningkatkan keberlanjutan industri ini.

Untuk penelitian selanjutnya, menyarankan penelitian lebih lanjut yang juga mempertimbangkan faktor-

faktor eksternal seperti kondisi cuaca, dan perubahan kebijakan yang dapat memengaruhi produksi minyak kelapa sawit di Indonesia.

Daftar Rujukan

- [1] F. Nadilla, "JENIS PENYAKIT PADA TANAMAN KELAPA SAWIT (*Elaeis guinensis* Jacq.) DAN TEKNIK PENGENDALIANNYA DI PT PERKEBUNAN NUSANTARA I KEBUN BARU AFDELING VI KOTA LANGSA," *BIOLOGICA SAMUDRA*, vol. 3, no. 2, pp. 133–140, Jan. 2022, doi: 10.33059/JBS.V3I2.2344.
- [2] E. P. Jelita, "Proses Pemeliharaan Bibit Unggul Kelapa Sawit di Desa Talang Danto Kecamatan Tapung Hulu," *JOURNAL OF COMMUNITY SERVICES PUBLIC AFFAIRS*, vol. 2, no. 2, pp. 45–55, Mar. 2022, doi: 10.46730/JCSPA.V2I2.42.
- [3] S. Sunanto, R. M. Taufiq, and R. Febri, "Implementasi Logika Fuzzy Inferensi Tsukamoto Pada Preventive dan Predictive Maintenance Sluge Separator Berbasis Smart Meter," *JURNAL FASILKOM*, vol. 13, no. 01, pp. 81–87, Jul. 2023, doi: 10.37859/JF.V13I01.5359.
- [4] F. Isharyadi *et al.*, "Analisis Titik Kritis Penjaminan Kualitas Benih Kelapa Sawit di Indonesia," *Jurnal Penelitian Kelapa Sawit*, vol. 30, no. 3, pp. 161–170, Dec. 2022, doi: 10.22302/IOPRI.JUR.JPKS.V30I3.187.
- [5] V. Budhidharma, "PENGARUH FAKTOR-FAKTOR FINANCIAL DAN EKONOMI TERHADAP HARGA MINYAK KELAPA SAWIT DI INDONESIA [IMPACT OF FINANCIAL AND ECONOMIC FACTORS TO PALM OIL PRICE IN INDONESIA]," 2020, doi: 10.19166/JPA.V1I2.2781.
- [6] I. Maryam, T. J. Arsita, H. Stevanus, and E. Nisa, "PEMODELAN SEMIVARIOGRAM EKSPERIMENTAL PADA JUMLAH PENYEBARAN PRODUKSI KELAPA SAWIT DI INDONESIA," *Fraction: Jurnal Teori dan Terapan Matematika*, vol. 2, no. 2, pp. 60–65, Dec. 2022, doi: 10.33019/FRACTION.V2I2.35.
- [7] R. N. Yanti, A. T. Ratnaningsih, and H. Ikhsani, "Pembuatan bio-briket dari produk pirolisis biochar cangkang kelapa sawit sebagai sumber energi alternatif," *Jurnal Ilmiah Pertanian*, vol. 19, no. 1, pp. 11–18, Mar. 2022, doi: 10.31849/JIP.V19I1.7815.
- [8] I. G. Anjani, A. B. Saputri, A. N. P. Armeira, and D. Januarita, "Analisis Konsumsi Dan Produksi Minyak Kelapa Sawit Di Indonesia Dengan Menerapkan Metode Moving Average," *JURIKOM (Jurnal Riset Komputer)*, vol. 9, no. 4, p. 1014, Aug. 2022, doi: 10.30865/JURIKOM.V9I4.4506.
- [9] S. Latsiya, "TEKNOLOGI PROSES UNTUK PRODUKSI BIODIESEL BERBASIS MINYAK KELAPA SAWIT," *WARTA Pusat Penelitian Kelapa Sawit*, vol. 27, no. 2, pp. 78–91, Jun. 2022, doi: 10.22302/IOPRI.WAR.WARTA.V27I2.75.
- [10] D. Marcelina, E. Yulianti, and Z. R. Mair, "Penerapan Metode Forward Chaining Pada Sistem Pakar Identifikasi Penyakit Tanaman Kelapa Sawit," *Jurnal Ilmiah Informatika Global*, vol. 13, no. 2, Aug. 2022, doi: 10.36982/JIIG.V13I2.2299.
- [11] W. F. Riski, "PENGARUH CEKAMAN KEKERINGAN TERHADAP FISILOGI DAN PRODUKSI KELAPA SAWIT," *WARTA Pusat Penelitian Kelapa Sawit*, vol. 26, no. 3, pp. 142–153, Oct. 2021, doi: 10.22302/IOPRI.WAR.WARTA.V26I3.45.
- [12] S. Sisnayati, D. S. Dewi, R. Apriani, and M. Faizal, "Penurunan BOD, TSS, minyak dan lemak pada limbah cair pabrik kelapa sawit menggunakan proses aerasi plat berlubang," *Jurnal Teknik Kimia*, vol. 27, no. 2, pp. 38–45, Jul. 2021, doi: 10.36706/JTK.V27I2.559.
- [13] N. M. Sunariadi *et al.*, "Prediksi Produksi Bawang Merah Di Kabupaten Nganjuk Dengan Metode Seasonal Arima (Sarima)," *scholar.archive.org/NM Sunariadi, PK Intan, DCR Novitasari, Y Hariningsih Transformasi: Jurnal Pendidikan Matematika dan Matematika*,

-
- 2022•*scholar.archive.org*, vol. 6, no. 1, pp. 49–60, 2022, doi: 10.36526/tr.v%vi%i.1672.
- [14] E. F. Putra, Y. Asdi, and M. Maiyastri, “PERAMALAN DENGAN METODE PEMULUSAN EKSPONENSIAL HOLT-WINTER DAN SARIMA (Studi Kasus: Jumlah Produksi Ikan (Ton) di Kota Sibolga Tahun 2000-2017),” *Jurnal Matematika UNAND*, vol. 8, no. 1, p. 75, Jul. 2019, doi: 10.25077/jmu.8.1.75-83.2019.
- [15] M. Handrianto and H. Cipta, “Peramalan Jumlah Produksi Minyak Kelapa Sawit Menggunakan Metode Holt-Winters Exponential Smoothing (Studi Kasus: PT. Sinar Gunung Sawit Raya),” *Jurnal Absis: Jurnal Pendidikan Matematika dan Matematika*, vol. 6, no. 1, pp. 781–793, 2023, doi: 10.30606/ABSIS.V6I1.2165.
- [16] D. M. Sihombing and W. Setiafindari, “PERAMALAN PRODUKSI CRUDE PALM OIL DENGAN ALGORITMA BACKPROPAGATION NEURAL NETWORK,” *Industri Inovatif: Jurnal Teknik Industri*, vol. 13, no. 1, pp. 27–31, Jun. 2023, doi: 10.36040/INDUSTRI.V13I1.4887.
- [17] R. A. M. Yusuf and T. S. Yanti, “Perbandingan Metode Seasonal Autoregressive Integreted Moving Average (SARIMA) dan Metode Fuzzy Time Series untuk Model Peramalan Jumlah Wisatawan Mancanegara di Bali,” 2021, doi: 10.29313/V0I0.29204.
- [18] W. Hariadi and S. Sulantari, “Pemodelan Kasus Pasien Terkonfirmasi Positif Covid-19 Per-Hari Di Indonesia dengan Metode SARIMA,” *Unisda Journal of Mathematics and Computer Science (UJMC)*, vol. 7, no. 2, pp. 19–30, Dec. 2021, doi: 10.52166/UJMC.V7I2.2743.
- [19] H. Mukhtar, Y. Rizki, F. A. Wenando, and M. A. Al Aziz, “Prediksi Kunjungan Wisatawan dengan Reduksi Noise pada Google Trends menggunakan Hilbert-Huang Transform dan Long Short-Term Memory,” *JURNAL FASILKOM*, vol. 12, no. 3, pp. 152–159, Dec. 2022, doi: 10.37859/JF.V12I3.4332.