

PENERAPAN TIME SERIES UNTUK PREDIKSI PRODUKSI MINYAK KELAPA SAWIT DI PT. DWIE WARNA KARYA

Application of Time Series For Palm Oil Production Prediction At PT. Dwie Warna Karya

Elsa Monica Putri¹, Veny Cahya Hardita², Catharina Elmayantie³

STMIK Palangkaraya^{1,2,3}

elsamputri9@gmail.com¹, vencahya@stmikplk.ac.id², catharinaelmayantie@gmail.com³

ABSTRAK

Fluktuasi produksi minyak kelapa sawit di PT. Dwie Warna Karya berdampak negatif pada efisiensi dan profitabilitas perusahaan. Penelitian ini bertujuan untuk mengimplementasikan metode Time Series dengan model SARIMA guna memprediksi produksi minyak kelapa sawit secara akurat, sehingga perusahaan dapat mengambil keputusan yang lebih baik dalam perencanaan produksi dan operasional. Metode penelitian ini adalah kuantitatif dengan pendekatan deskriptif dan prediktif, menggunakan data yang dikumpulkan melalui wawancara, studi pustaka, dan dokumentasi data produksi historis. Model SARIMA yang digunakan adalah $(1,1,1)(1,1,1)_{12}$ diidentifikasi sebagai model yang paling sesuai untuk memprediksi produksi minyak kelapa sawit dalam 12 bulan ke depan. Model ini menunjukkan bahwa produksi dipengaruhi oleh nilai-nilai sebelumnya, tren yang perlu differencing satu kali, serta komponen random yang dipengaruhi oleh kesalahan prediksi sebelumnya, baik dalam jangka pendek maupun musiman. Model SARIMA ini membantu dalam peramalan yang lebih akurat dan dapat digunakan sebagai acuan dalam perencanaan produksi, pengelolaan stok, dan pengambilan keputusan strategis lainnya.

Kata kunci: Machine Learning, Minyak Kelapa Sawit, SARIMA, Time Series

ABSTRACT

Fluctuations in palm oil production at PT. Dwie Warna Karya negatively impact the company's efficiency and profitability. This study aims to implement the Time Series method using the SARIMA model to accurately predict palm oil production, enabling the company to make better decisions in production planning and operations. This research employs a quantitative approach with descriptive and predictive analysis, utilizing data collected through interviews, literature studies, and historical production documentation. The SARIMA $(1,1,1)(1,1,1)_{12}$ model is identified as the most suitable for forecasting palm oil production over the next 12 months. The model indicates that production is influenced by previous values, requires first-order differencing to address trends, and includes a random component affected by prior forecasting errors, both in the short-term and seasonal patterns. This SARIMA model enhances forecasting accuracy and serves as a valuable reference for production planning, inventory management, and strategic decision-making.

Keywords: Machine Learning, Palm Oil, SARIMA, Time Series

Pendahuluan

Minyak kelapa sawit juga merupakan salah satu komoditas strategis yang memainkan peran penting dalam perekonomian Indonesia, terutama sebagai penyumbang devisa negara melalui ekspor, adalah minyak kelapa sawit. Produk turunan minyak kelapa sawit digunakan dalam berbagai industri, termasuk makanan, kosmetik, dan bahan bakar nabati, atau biofuel, yang memiliki permintaan yang terus meningkat di seluruh dunia. Negara Indonesia merupakan salah satu negara yang berpotensi pada sektor pertanian. Wilayah Indonesia yang luas tersebar di berbagai wilayah dan kondisi tanahnya yang subur dapat dikembangkan untuk memajukan pertanian Indonesia.

Perkebunan merupakan sub sektor pertanian. Salah satu komoditi perkebunan yang sangat berpeluang untuk meningkatkan perekonomian adalah kelapa sawit (*Elaeis guineensis*) merupakan tanaman yang dapat menghasilkan minyak kelapa sawit mentah (CPO) dan inti kelapa sawit (kernel) (Levia & Mhubaligh, 2023). Minyak sawit atau *Crude Palm Oil (CPO)* merupakan produk utama dari perkebunan kelapa sawit yang mengalami pertumbuhan produksi signifikan, dengan rata-rata pertumbuhan sebesar 10,13% selama 3 dasawarsa terakhir. Mayoritas produksi minyak kelapa sawit Indonesia diekspor. Proporsi CPO yang diproduksi di Indonesia di pasar global masih terus meningkat (Yudha & Bagaskara, 2024).

Peneliti menggunakan metode *Time series*, yang sering digunakan dalam analisis data yang melibatkan runtun waktu, untuk mempelajari pola, tren, dan musim (*seasonality*) yang ada dalam data (Wahyudi & Mujilawati, 2023) (Wibowo, 2018) (Durrach, Yulia, Parhusip, & Rusyana, 2018). Metode yang sesuai untuk merumuskan masalah prediksi permintaan adalah *ARIMA* dan *Seasonal SARIMA*. Dengan menggunakan metode *Autoregressive Integrated Moving Average (ARIMA)* dan *Seasonal Autoregressive Integrated Moving Average (SARIMA)* untuk melakukan pendekatan yang dapat membantu dalam menentukan berapa jumlah persediaan yang harus disediakan untuk mendukung penjualan yang optimal. Untuk pola data berkarakteristik tidak stasioner dan *SARIMA* untuk pola data musiman. metode tersebut dengan menguji stationeritas ragam dan rata-rata pada data, menguji signifikansi *ACF* dan *PACF*, pemeriksaan diagnostik, dan uji asumsi residual dapat memprediksi jumlah permintaan atau penjualan produk beberapa periode kedepan (Suseno & Wibowo, 2023). Metode ini sangat berguna untuk memprediksi output produksi, terutama dalam produksi minyak kelapa sawit, tren produksi dapat berubah seiring waktu karena faktor musiman, lingkungan, dan efisiensi operasional (Tokan & Hermawan, 2023) (Ruhiat & Effendi, 2018).

Implementasi metode ini dilakukan dengan bantuan *Google Colab*, sebuah platform berbasis cloud yang mendukung pengolahan data dalam skala besar dan menyediakan lingkungan pemrograman yang efisien untuk menjalankan algoritma *Machine Learning* (Soen, Marlina, & Renny, 2022) (Nazar, 2024).

Berdasarkan uraian di atas, peneliti menganalisis produksi minyak kelapa sawit menggunakan metode *Time series*, yang bertujuan untuk memprediksi jumlah produksi di masa mendatang berdasarkan data historis. Analisis ini diharapkan dapat mengidentifikasi pola produksi, fluktuasi musiman, serta tren jangka panjang yang mempengaruhi output perusahaan. Dengan demikian, prediksi yang dihasilkan akan membantu perusahaan dalam merencanakan strategi operasional yang lebih efisien, mengoptimalkan penggunaan sumber daya, dan meminimalkan risiko kerugian. Selain itu, hasil dari prediksi ini dapat digunakan untuk meningkatkan perencanaan distribusi, pengelolaan stok, dan pengambilan keputusan terkait produksi minyak kelapa sawit yang lebih berkelanjutan.

Metode

Penelitian ini menggunakan metode kuantitatif dengan pendekatan *time series* untuk memprediksi hasil produksi minyak kelapa sawit (CPO) dari PT. Dwie Warna Karya dalam rentang waktu 2022-2024. Model prediksi yang digunakan adalah *Seasonal Autoregressive Integrated Moving Average (SARIMA)*, yang merupakan salah satu metode dalam analisis deret waktu untuk menangkap pola musiman dalam data produksi.

Data yang digunakan dalam penelitian ini diperoleh dari hasil produksi CPO PT. Dwie Warna Karya yang tercantum dalam Tabel 1. Model *SARIMA* dipilih karena kemampuannya dalam menangani tren dan pola musiman yang terdapat dalam data produksi CPO.

Tabel berikut menunjukkan hasil produksi CPO berdasarkan data historis yang digunakan.

Tabel 1. Hasil Produksi (CPO) PT. Dwie Warna Karya 2022-2024

Periode	Bulan Prediksi	Tahun	Crude Palm Oil (CPO)
1	Januari		3.269
2	Februari		4.667
3	Maret		4.570
4	April		4.709
5	Mei	2	5.319
6	Juni	0	6.296
7	Juli	2	6.237
8	Agustus	2	5.838
9	September		5.816
10	Oktober		5.606
11	November		4.963
12	Desember		4.465
13	Januari		4.074
14	Februari		3.006
15	Maret		2.971
16	April		3.067
17	Mei	2	2.973
18	Juni	0	3.783
19	Juli	2	4.203
20	Agustus	3	4.543
21	September		4.116
22	Oktober		3.835
23	November		3.537
24	Desember		3.226

25.	Januari	3.222	
26.	Februari	2.468	
27.	Maret	3.014	
28.	April	3.592	
29.	Mei	2	3.068
30.	Juni	0	2.952
31.	Juli	2	2.952
32.	Agustus	4	3.776
33.	September		3.696
34.	Oktober		3.852
35.	November		3.502

Hasil Dan Pembahasan

Langkah dalam implementasi prediksi Time series dengan model SARIMA adalah dengan melakukan training pada data yang sudah diimport pada Google Colab. Berikut adalah proses implementasi yang dilakukan di Google Colab.

```

n untuk menambah fungsi pada code
import pandas as pd
import datetime
from datetime import date, timedelta
import matplotlib.pyplot as plt
plt.style.use('fivethirtyeight')
from statsmodels.tsa.seasonal import seasonal_decompose
from statsmodels.tsa.arima.model import ARIMA
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
from statsmodels.tsa.stattools import adfuller
import statsmodels.api as sm
import warnings
    
```

Gambar 1. Menambahkan fungsi pada kode di Google Colab

Kode pada Gambar 1 di atas mengimpor berbagai pustaka Python yang umum digunakan untuk analisis deret waktu (time series). *Pandas* digunakan untuk manipulasi data dalam bentuk *DataFrame*, sementara *datetime* menyediakan fungsi untuk bekerja dengan tanggal dan waktu. *Matplotlib* digunakan untuk visualisasi data, terutama *plot*. *statsmodels* adalah pustaka statistik yang menyediakan berbagai model dan alat untuk analisis deret waktu, termasuk dekomposisi musiman (*seasonal_decompose*), model *ARIMA* (*ARIMA*), *plot autokorelasi* (*plot_acf*), *plot autokorelasi parsial* (*plot_pacf*), uji akar unit (*adfuller*), dan lainnya. *warnings* digunakan untuk mengelola pesan peringatan yang muncul selama eksekusi kode. Dengan kata lain, kode ini menyiapkan lingkungan kerja *Python* dengan semua alat yang diperlukan untuk menganalisis data deret waktu.

Tahap selanjutnya adalah *Data exploration* adalah untuk menganalisis tren dengan cara visualisasi grafik, memudahkan untuk melihat ada peningkatan atau

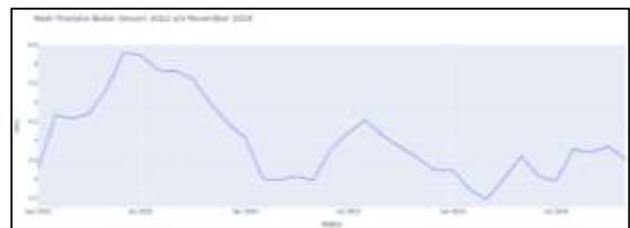
penurunan penjualan secara keseluruhan, serta mengidentifikasi adanya pola musiman. Berikut adalah gambar proses *data exploration* pada *Google Colab*, di Gambar 2.

```

# membuat plot produksi
import matplotlib.pyplot as plt
fig = plt.figure(figsize=(10,5), title="hasil produksi bulan Januari 2022 s/d November 2024")
fig.autofmt()
    
```

Gambar 2. Proses Data Exploration

Hasil dari proses data Exploration adalah membuat dan menampilkan sebuah grafik garis (*line plot*) yang menunjukkan tren produksi *CPO* (*Crude Palm Oil*) dari bulan Januari 2022 hingga November 2024. Grafik ini akan sangat berguna untuk melihat secara visual bagaimana produksi *CPO* berubah dari waktu ke waktu. Grafik menunjukkan tren produksi *CPO* dari Januari 2022 hingga November 2024, dengan fluktuasi yang mencerminkan faktor-faktor periodik. Puncak dan lembah produksi menandakan variasi dalam output, memberikan gambaran visual perkembangan *CPO* dalam jangka waktu yang panjang. Grafik tersebut dapat dilihat pada Gambar 3.



Gambar 3. Grafik hasil data exploration

Data diuji dengan menggunakan *ADF Test* (*Augmented Dickey-Fuller*). Jika data tidak stasioner, dilakukan *differencing* untuk membuatnya stasioner. Pada penelitian ini, peneliti melakukan *differencing* karena terdapat data yang tidak stasioner, berikut adalah proses yang dilakukan, pada Gambar 4.

```

# melakukan differencing untuk memastikan data stasioner
# mengubah kolom 'waktu' ke datetime objects jika belum
data['waktu'] = pd.to_datetime(data['waktu'])
# mencari perbedaan dalam kolom 'CPO' saja
data_diff = data[['CPO']].diff().dropna()

# melakukan uji ADF
result = adfuller(data_diff['CPO'])
print('ADF statistic: %f' % result[0])
print('p-value: %f' % result[1])

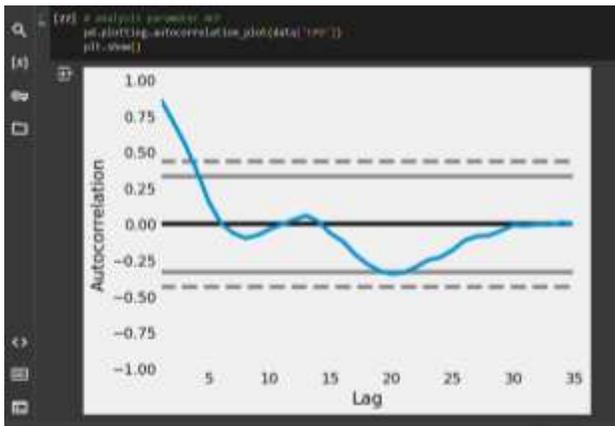
ADF Statistic: -5.002587
p-value: 0.000022
    
```

Gambar 4. Proses differencing data

Hasil uji *ADF* menunjukkan nilai statistik - 5,002587 dengan *p-value* 0,000022, yang jauh lebih kecil dari tingkat signifikansi 0,05. Dengan demikian, hipotesis nol bahwa data tidak stasioner ditolak, sehingga data

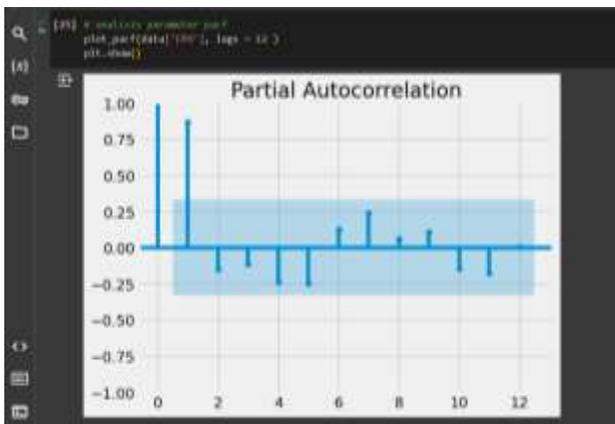
produksi CPO setelah differencing dapat dianggap stasioner. Hal ini mengindikasikan bahwa nilai D dalam model SARIMA (P,D,Q)s adalah 1.

Selanjutnya dilakukan Analisis parameter SARIMA dilakukan dengan melihat ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*) untuk menentukan nilai p (*autoregressive*), d (*differencing*), dan q (*moving average*) yang optimal untuk model. Proses analisis pada Gambar 5.



Gambar 5. Analisis ACF

Plot hasil analisis menunjukkan pola autokorelasi dalam data produksi CPO. Jika autokorelasi pada lag tertentu melewati batas signifikansi, berarti terdapat hubungan signifikan antara produksi CPO saat ini dan sebelumnya. Pola ini membantu mengidentifikasi struktur dependensi data dan menentukan nilai Q dalam model SARIMA (P,D,Q)s, yaitu 1. Selanjutnya dilakukan proses analisis PACF pada Gambar 6.



Gambar 6. Analisis PACF

Plot yang dihasilkan menunjukkan pola *Partial Autocorrelation* pada data produksi CPO. Jika nilai PACF pada lag tertentu berada di luar batas signifikansi (area biru

muda), maka dapat disimpulkan bahwa terdapat korelasi langsung yang signifikan antara nilai produksi CPO pada periode tersebut dengan nilai produksi pada periode sebelumnya yang berjarak satu lag, setelah memperhitungkan pengaruh dari lag-lag sebelumnya. Berdasarkan hasil PACF tersebut dapat disimpulkan bahwa nilai P pada SARIMA (P,D,Q)s adalah 1. Setelah ditentukan nilai pada model SARIMA, maka nilai tersebut dimasukkan kedalam kode sebagai fungsi untuk selanjutnya dibangun menggunakan Model SARIMA.

Perhitungan SARIMA menggunakan model (1,1,1)(1,1,1)12 pada Gambar 2.

```

# sarima building
from statsmodels.tools.exceptions import ConvergenceWarning
warnings.simplefilter('ignore', ConvergenceWarning)

model = sm.tsa.statespace.SARIMA(data['CPO'], order=(p,d,q), seasonal_order=(P,D,Q,12))
model = model.fit()

print(model.summary())
    
```

Gambar 7. Kode untuk proses membangun SARIMA.

Pertama, kode mengimpor modul *ConvergenceWarning* untuk mengabaikan peringatan konvergensi yang muncul saat fitting model. Kemudian, sebuah objek model SARIMA dibuat dengan menentukan parameter *order (p,d,q)* untuk komponen *autoregresif, integrasi, dan moving average, serta seasonal_order (P,D,Q,s)* untuk komponen musiman. Setelah itu, model tersebut di-fit ke data produksi CPO. Terakhir, kode mencetak ringkasan dari model yang telah di-fit, yang akan menampilkan informasi seperti koefisien model, nilai-nilai statistik uji, dan kualitas penyesuaian model. Hasil dari proses prediksi tersebut dapat dilihat pada Gambar 8.

SARIMAX Results						
Dep. Variable:	CPO	No. Observations:	35			
Model:	SARIMAX(1, 1, 1)x(1, 1, 1, 12)	Log Likelihood:	-21.476			
Date:	Mon, 09 Dec 2024	AIC:	52.952			
Time:	03:54:49	BIC:	58.407			
Sample:	0	HQIC:	54.237			
	-35					
Covariance Type:	opg					
	coef	std err	z	P> z	[0.025	0.975]
ar.L1	-0.3296	0.409	-0.807	0.420	-1.130	0.471
ma.L1	0.9986	6.951	0.143	0.887	-12.634	14.615
ar.S.L12	-0.7332	83.727	-0.009	0.993	-164.834	163.368
ma.S.L12	0.5203	98.203	0.005	0.996	-191.954	192.995
sigma2	0.3458	3.400	0.102	0.919	-6.319	7.018
Ujung-Box (11) (Q):	2.26	Jarque-Bera (30):	17.85			
Prob(Q):	0.13	Prob(30):	0.00			
Heteroskedasticity (H):	0.35	Skew:	-1.66			
Prob(H) (two-sided):	0.19	Kurtosis:	5.91			
Warnings:						
[1] Covariance matrix calculated using the outer product of gradients (complex-step).						

Gambar 8. Hasil pembangunan SARIMA

Gambar di atas menunjukkan hasil estimasi model SARIMA (Seasonal AutoRegressive Integrated Moving Average) untuk data produksi CPO. Model yang digunakan adalah SARIMAX(1,1,1)x(1,1,1,12) yang berarti terdapat 1 orde autoregresif, 1 orde differencing, dan 1 orde moving average pada komponen non-musiman, serta 1 orde autoregresif, 1 orde differencing, dan 1 orde moving average pada komponen musiman dengan periode 12 (bulanan). Hasil estimasi menunjukkan nilai koefisien dari masing-masing parameter model, standar error, nilai z, p-value, dan interval kepercayaan.

Sebelum memasuki tahap prediksi, Model Evaluation dilakukan untuk mengevaluasi hasil prediksi, kode terlebih dahulu mengimpor pustaka Pandas untuk manipulasi data, lalu mencetak statistik deskriptif dari hasil prediksi yang tersimpan dalam DataFrame prediction_df. Proses evaluasi pada Gambar 9.

```

# Prediction Model
prediction = model.predict(len(data), len(data)+11)
for index, value in prediction.items():
    print("{}({index}): {value:.3f}")

mean of prediction: 2.539536052094463
standard deviation of prediction: 0.623594432736022
minimum of prediction: 1.7372216099701169
maximum of prediction: 3.144161087096359
    
```

Gambar 9. Model Evaluasi

Pada model evaluation juga melakukan pengecekan missing values dan negatif untuk melihat nilai yang tidak terdefiniskan, proses dilakukan pada Gambar 10.

```

print("Input: ", data.head(), "\n")
print("Missing Values: ", data["CPO"].isnull().sum())
print("Negatif: ", data["CPO"].lt(0).sum())
    
```

Gambar 10. Menghitung missing dan negatif values

Hasil output menunjukkan bahwa tidak ada nilai negatif atau nol pada kolom 'CPO' dan tidak ada pula nilai yang hilang. Ini mengindikasikan bahwa data produksi CPO dalam kondisi yang baik dan siap untuk digunakan dalam analisis selanjutnya.

Tahap terakhir adalah prediksi untuk memproyeksikan hasil produksi minyak kelapa sawit (CPO) di masa mendatang.

```

# Prediction Model
prediction = model.predict(len(data), len(data)+11)
for index, value in prediction.items():
    print("{}({index}): {value:.3f}")

35: 3.121
36: 2.892
37: 1.929
38: 1.738
39: 2.176
40: 2.510
41: 2.264
42: 2.332
43: 3.144
44: 2.934
45: 2.979
46: 2.695
    
```

Gambar 11. Model Prediksi

kode ini melakukan prediksi untuk 12 periode ke depan berdasarkan model yang telah dilatih sebelumnya, kemudian menampilkan hasil prediksi tersebut dalam format yang mudah dibaca. Hasil output yang ditampilkan menunjukkan nilai prediksi untuk setiap periode, yang dapat digunakan untuk analisis lebih lanjut atau pengambilan keputusan.

Pada Tabel 2 terdapat hasil prediksi selama 12 periode ke depan, berdasarkan tabel Tabel 2 lonjakan produksi minyak kelapa sawit terjadi pada bulan Agustus 2025 dengan jumlah produksi 3.144 liter.

Tabel 2. Hasil Prediksi

No	Periode waktu	Bulan Prediksi	Tahun	Crude Palm Oil (CPO)
1.	35	Desember	2025	3.121
2.	36	Januari		2.892
3.	37	Februari		1.929
4.	38	Maret		1.738
5.	39	April		2.176
6.	40	Mei		2.510
7.	41	Juni		2.264
8.	42	Juli		2.332
9.	43	Agustus		3.144
10.	44	September		2.934
11.	45	Oktober		2.979
12.	46	November		2.695

Simpulan Dan Saran

Penelitian ini berhasil menerapkan metode Time Series untuk memprediksi produksi minyak kelapa sawit di PT Dwie Warna Karya menggunakan model SARIMA (1,1,1)(1,1,1)12_{12}. Model ini terbukti mampu menangkap pola musiman dan tren produksi dengan baik, sehingga dapat digunakan sebagai alat bantu dalam

perencanaan produksi, pengelolaan inventori, dan pengambilan keputusan strategis. Berdasarkan hasil prediksi, produksi minyak kelapa sawit untuk periode Desember 2024 hingga November 2025 diperkirakan mengalami fluktuasi tanpa tren kenaikan atau penurunan yang signifikan. Dengan tingkat akurasi yang tinggi, model SARIMA yang dikembangkan dapat diandalkan untuk memproyeksikan produksi satu tahun ke depan, membantu perusahaan dalam mengoptimalkan strategi bisnisnya.

References

- Durrah, F. I., Yulia, Parhusip, T. P., & Rusyana, A. (2018). Peramalan Jumlah Penumpang Pesawat Di Bandara Sultan Iskandar Muda Dengan Metode SARIMA (Seasonal Autoregressive Integrated Moving Average). *Journal of Data Analysis*, 1-11.
- Levia, D., & Mhubaligh. (2023). Analisis Proses Produksi CPO Untuk Mengidentifikasi Faktor-Faktor Yang Mempengaruhi Kualitas Mutu CPO. *Jurnal Teknologi dan Manajemen Industri Terapan*, 82-89.
- Nazar, R. (2024). Implementasi Pemrograman Python Menggunakan Google Colab. *Jurnal Informatika dan Komputer (JIK)*, 50-56.
- Ruhiat, D., & Effendi, A. (2018). Pengaruh Faktor Musiman Pada Pemodelan Deret Waktu Untuk Peramalan Debit Sungai Dengan Metode Sarima. *Jurnal Teori dan Riset Matematika (TEOREMA)*, 117-128.
- Soen, G. I., Marlina, & Renny. (2022). Implementasi Cloud Computing dengan Google Colaboratory pada Aplikasi Pengolah Data Zoom Participants. *JITU : Journal Informatic Technology And Communication*, 24-30.
- Suseno, & Wibowo, S. (2023). Penerapan Metode ARIMA dan SARIMA Pada Peramalan Penjualan Telur Ayam Pada PT Agromix Lestari Group. *Jurnal Teknologi dan Manajemen Industri Terapan*, 33-40.
- Tokan, L. F., & Hermawan, A. (2023). Implementasi Model SARIMA Untuk Memprediksi Produksi Minyak Kelapa Sawit. *Jurnal Fasilkom*, 456-563.
- Wahyudi, A., & Mujilawati, S. (2023). Implementasi Metode Time Series untuk Prediksi dan Monitoring Pendapatan Masla Delivery Berbasis Website. *Joutica*, 1-6.
- Wibowo, A. (2018). Model Peramalan Indeks Harga Konsumen Kota Palangka Raya Menggunakan Seasonal ARIMA (SARIMA). *Jurnal Teori dan terapan Matematika*, 17-24.
- Yudha, E. P., & Bagaskara, F. (2024). Analisis Daya Saing Ekspor Kelapa Sawit (CPO) Indonesia dan Malaysia di India. *Agroinfo Galuh Jurnal Ilmiah Mah*, 1212-1227.