

Analisis Peramalan Produksi Tanaman Kelapa Sawit Menggunakan Metode Arima pada PTPN Kebun Sukamaju

Riyan Mirdan Faris¹, Kalfajrin Kurniaji², Dana Budiman³, Yoedani⁴, Mulus Wijaya Kusuma⁵,
Fitrina Lestari⁶

¹Universitas Nusa Putra; riyan.mirdan@nusaputra.ac.id

²Universitas Nusa Putra; kalfajrin.kurniaji@nusaputra.ac.id

³Universitas Nusa Putra; dana.budiman@nusaputra.ac.id

⁴Universitas Nusa Putra; yoedani@nusaputra.ac.id

⁵Universitas Nusa Putra; mulus.wijaya@nusaputra.ac.id

⁶Universitas Nusa Putra; fitrina.lestari@nusaputra.ac.id

Article Info

Article history:

Received Agustus, 2024

Revised Agustus, 2024

Accepted Agustus, 2024

Kata Kunci:

Production ARIMA, Management Forecasting, Operational

Keywords:

Peramalan Produksi, ARIMA, Manajemen Operasional

ABSTRAK

Industri kelapa sawit Indonesia memainkan peran penting dalam sektor ekonomi dan sosial dengan memberikan kontribusi signifikan terhadap pendapatan nasional. Penelitian ini berfokus pada peramalan produksi kelapa sawit di PTPN Kebun Sukamaju, Jawa Barat, menggunakan model ARIMA untuk mendukung manajemen operasional. Data sekunder produksi bulanan dari 2016 hingga 2023 dianalisis dengan pendekatan mixed methods, menggunakan perangkat lunak R-Studio. Model ARIMA (1,1,3) (1,0,1) [12] dipilih sebagai model terbaik setelah melalui identifikasi, estimasi parameter, dan pemeriksaan diagnostik. Hasil peramalan menunjukkan penurunan produksi dengan nilai MAPE sebesar 12,49%.

ABSTRACT

The Indonesian palm oil industry plays a crucial role in the economic and social sectors by making a significant contribution to national income. This study focuses on forecasting palm oil production at PTPN Kebun Sukamaju, West Java, using the ARIMA model to support operational management. Monthly production data from 2016 to 2023 were analyzed using a mixed methods approach, with R-Studio software. The ARIMA (1,1,3) (1,0,1) [12] model was selected as the best model after undergoing identification, parameter estimation, and diagnostic checks. The forecasting results indicate a decline in production with a MAPE value of 12.49%.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



Corresponding Author:

Name: Riyan Mirdan Faris

Institution: Universitas Nusa Putra

Email: riyan.mirdan@nusaputra.ac.id

1. PENDAHULUAN

Indonesia merupakan negara yang didominasi oleh sektor pertanian, dengan perkebunan sebagai salah satu kontributor utama bagi ekonomi dan sosial nasional. Kelapa sawit, sebagai salah satu komoditas unggulan, berperan signifikan dalam pendapatan negara serta menjadi sumber penghasilan bagi banyak petani dan perusahaan perkebunan. Kelapa sawit telah memberikan dampak positif terhadap pertumbuhan ekonomi, pembangunan pedesaan, dan upaya pengentasan kemiskinan, terutama di Indonesia yang merupakan salah satu produsen terbesar minyak kelapa sawit di dunia (Edwards et al., 2019; Kubitz et al., 2018). Produksi kelapa sawit sangat penting dan harus dipertimbangkan secara matang sebagai pendorong pembangunan ekonomi di negara-negara berkembang. Industri kelapa sawit dapat memberikan peluang lapangan kerja dan meningkatkan pendapatan penduduk miskin jika dikelola secara sistematis (Rahim et al., 2018). Hasil penelitian yang dilakukan oleh (Kubitz et al., 2018; Santika et al., 2019) menjelaskan bahwa produksi kelapa sawit di Indonesia merupakan usaha yang menguntungkan dan mampu meningkatkan pendapatan petani kecil.

Berdasarkan data dari Badan Pusat Statistik (2023) ekspor crude palm oil (CPO) Indonesia menunjukkan pertumbuhan signifikan, mencapai US\$216,74 miliar dari 2012 hingga 2022, dengan rekor tertinggi sebesar US\$29,62 miliar pada tahun 2022. Tren ini menunjukkan pentingnya industri minyak sawit bagi perekonomian nasional dan kontribusinya terhadap perdagangan internasional. Namun, industri ini juga menghadapi tantangan besar, termasuk perubahan iklim, fluktuasi harga, dan isu lingkungan, yang menuntut akurasi tinggi dalam peramalan produksi untuk mendukung perencanaan dan manajemen yang efektif.

Salah satu metode peramalan yang banyak digunakan dalam pengembangan model produksi adalah Autoregressive Integrated Moving Average (ARIMA). Metode ini telah menjadi pilihan umum karena kemampuannya dalam menangani data deret waktu dan memperhitungkan pola autoregresi, integrasi, serta pergerakan rata-rata. Asumsi utama dari model-model ini adalah bahwa dalam analisis runtun waktu terdapat aspek pola masa lalu yang akan tetap ada di masa depan (Mgaya, 2019). ARIMA adalah model peramalan deret waktu yang memanfaatkan informasi masa lalu dan nilai error sebelumnya untuk meramalkan nilai masa depan (Afeef et al., 2018). Metode ini juga digunakan untuk menganalisis dampak intervensi terhadap data, termasuk kapan intervensi mulai berdampak, besarnya dampak, dan apakah dampaknya bersifat sementara atau permanen (Nasution & Wulansari, 2019).

Penelitian ini berfokus pada penerapan model ARIMA untuk meramalkan produksi kelapa sawit di PTPN Kebun Sukamaju, yang merupakan bagian dari KSO PTPN III (Persero) di Jawa Barat. Produksi di kebun ini mengalami fluktuasi signifikan selama delapan tahun terakhir, menekankan pentingnya peramalan yang akurat untuk mendukung pengambilan keputusan manajerial dalam mengelola risiko dan mengoptimalkan operasi. Penelitian ini bertujuan untuk memberikan wawasan yang lebih komprehensif tentang penerapan metode peramalan dalam mendukung manajemen produksi kelapa sawit dan menjadi dasar bagi pengembangan model yang lebih efisien di masa depan, dengan harapan meningkatkan efisiensi operasional serta profitabilitas industri.

2. TINJAUAN PUSTAKA

Menurut Heizer dan Render, manajemen operasional adalah pengelolaan menyeluruh yang optimal atas tenaga kerja, bahan mentah, peralatan, dan faktor produksi lainnya untuk menghasilkan produk barang dan jasa yang dapat diperjualbelikan secara umum (Wahjono, 2021). Zainul menambahkan bahwa manajemen produksi dan operasi mencakup berbagai aktivitas, dimulai dari analisis dan penetapan keputusan sebelum kegiatan produksi dan operasi dimulai, yang biasanya melibatkan keputusan jangka panjang, hingga persiapan dan pelaksanaan kegiatan produksi yang umumnya melibatkan keputusan jangka pendek (Zainul, 2019). Herjanto berpendapat bahwa manajemen operasional adalah proses berkelanjutan yang menggunakan

fungsi-fungsi manajemen untuk mengintegrasikan sumber daya secara efisien guna mencapai tujuan organisasi (Kristanto et al., 2022).

Industri kelapa sawit merupakan sektor pertanian terpenting di Indonesia (Harahap et al., 2020). Ekspansi kelapa sawit dianggap sebagai kunci pertumbuhan dan pembangunan ekonomi, dengan produksi yang terkoordinasi untuk memaksimalkan pendapatan (Krishna & Kubitza, 2021). Sejak tahun 2000-an, Indonesia telah menjadi produsen terbesar minyak kelapa sawit di dunia dan tetap menjadi komoditas ekspor utama negara (Ruml et al., 2022). Data Badan Pusat Statistik (BPS) 2023 menunjukkan bahwa sektor kelapa sawit berkontribusi signifikan terhadap perekonomian Indonesia, menyumbang 46,50 juta ton dari total volume minyak kelapa sawit dunia (Hidayatullah, 2023).

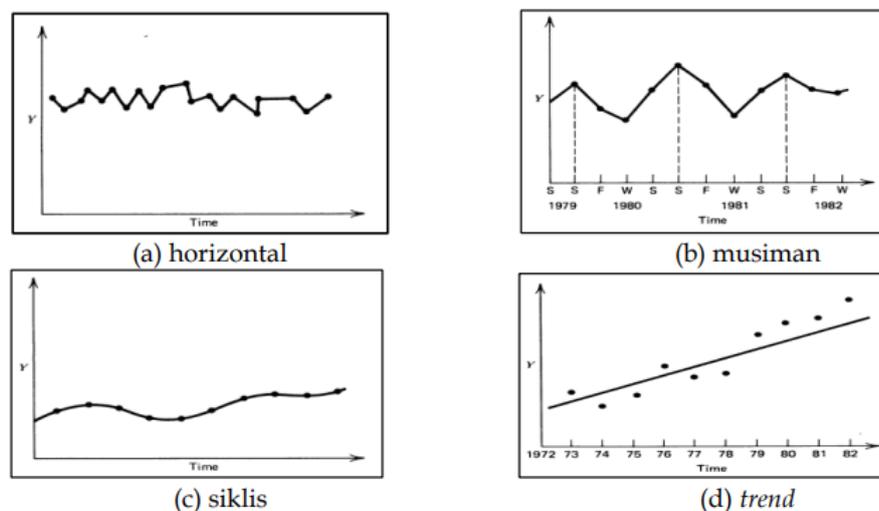
2.1 Peramalan (Forecasting)

Peramalan adalah proses analisis objektif yang menggunakan data historis untuk memprediksi berbagai aspek perusahaan seperti kuantitas, kualitas produksi dan berbagai aspek produksi serta hal lainnya di masa yang akan datang (Mahayana et al., 2022). Chambers dkk. mengemukakan bahwa peramalan merupakan bagian integral dari pengambilan keputusan ekonomi di seluruh dunia (GC & JunHo, 2020). Heizer & Render menambahkan bahwa peramalan adalah kombinasi antara seni dan ilmu dalam memprediksi kejadian di masa depan, melibatkan pengumpulan dan analisis data historis menggunakan model matematis untuk menghasilkan estimasi yang akurat tentang apa yang mungkin terjadi di masa depan (Ridwan & Tukhas, 2020). Kemudian menurut Taylor peramalan adalah upaya untuk membuat prediksi tentang peristiwa atau kondisi yang akan terjadi di masa depan (Yudi, 2018).

Analisis deret waktu mempelajari pengamatan data deret waktu dan membangun model untuk menggambarkan struktur data serta memprediksi nilai di masa mendatang (Siami & Namin, 2018). Granger dan Newbold menyatakan bahwa analisis deret waktu dapat memberikan perkiraan jangka pendek untuk sejumlah besar data mengenai variabel terkait dengan sangat tepat (Abonazel & Abd-Elftah, 2019; Hassan, 2020). Pendekatan peramalan deret waktu menggunakan pola data masa lalu untuk meramalkan data masa depan, membantu penganalisis dan pengambil keputusan membuat informasi yang jelas.

2.2 Jenis Pola Data

Makridakis dkk berpendapat bahwa tahap krusial dalam pemilihan model deret waktu adalah mempertimbangkan pola data yang ada, sehingga dapat menguji metode yang paling sesuai dengan pola tersebut (Yani et al., 2022). Pola dalam data runtun waktu dibedakan dalam beberapa jenis, yaitu horizontal, musiman, siklis dan tren (Setiawan et al., 2019).



Gambar 1. Jenis Pola Data

- 1) Pola horizontal, data bervariasi di sekitar nilai rata-rata konstan, menunjukkan stasioneritas pada nilai rata-ratanya.

- 2) Pola musiman, dipengaruhi oleh faktor musiman seperti peristiwa tahunan atau pola bulanan, mingguan, atau harian.
- 3) Pola siklis, dipengaruhi oleh fluktuasi jangka panjang dalam ekonomi, seperti siklus bisnis.
- 4) Pola tren, terjadi ketika ada perubahan arah naik atau turun dalam jangka panjang pada data.

2.3 Metode Autoregressive Integrated Moving Average (ARIMA)

Metode *Autoregressive Integrated Moving Average* (ARIMA), juga dikenal sebagai pendekatan *Box-Jenkins* (Pathak & Kapadia, 2021), adalah metode statistik fleksibel untuk peramalan deret waktu (Hassan, 2020). ARIMA mengintegrasikan elemen dari model *Autoregressive* (AR) dan *Moving Average* (MA) (Rahimi & Khashei, 2018). Metode ini efektif untuk peramalan jangka pendek, meskipun akurasi peramalan jangka panjang cenderung menurun karena hasilnya biasanya stabil untuk periode yang lebih lama (Salwa et al., 2018; Selvam et al., 2024). Model ARIMA dapat menangani berbagai jenis data setelah stasionerisasi dan cocok untuk memprediksi data yang berubah cepat (Rizkya et al., 2019). Proses ARIMA secara umum melibatkan empat langkah proses yaitu identifikasi model, estimasi parameter, pemeriksaan diagnostik dan peramalan (GC & JunHo, 2020).

2.4 Model Autoregressive (AR)

Dalam konteks model ini, semua nilai sebelumnya memiliki pengaruh aditif (kontribusi secara langsung dan terpisah) pada level Y_t , sehingga model ini memiliki memori jangka panjang (Abonazel & Abd-Elftah, 2019; Hal, 2021; Hassan, 2020). Sebuah model *Autoregressive* (autoregresif) dengan orde p , AR (p), dapat dinyatakan sebagai:

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

- Y_t : data deret waktu pada waktu ke t
- Y_{t-p} : data deret waktu pada waktu ke t sebelumnya sebanyak p
- μ : nilai konstanta
- ϕ_p : parameter autoregresif ke- p
- ε_t : nilai kesalahan pada waktu t .

2.5 Model Moving Average (MA)

Model ini dinyatakan dalam bentuk kesalahan masa lalu sebagai variabel penjelas. Oleh karena itu, hanya q kesalahan yang akan berpengaruh pada Y_t , namun kesalahan orde yang lebih tinggi tidak berpengaruh pada Y_t . Hal ini berarti model ini merupakan model memori pendek (Abonazel & Abd-Elftah, 2019; Hal, 2021; Hassan, 2020). Sebuah deret waktu (Y_t) dikatakan sebagai proses *Moving Average* (rata-rata bergerak) dengan orde q , MA (q), jika:

$$Y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

- Y_t : data deret waktu pada waktu ke t
- θ_q : parameter rata-rata bergerak ke- q
- ε_t : nilai kesalahan pada waktu t .

2.6 Model Autoregressive Moving Average (ARMA)

Model ARMA mencakup model *Autoregressive* (AR) dan *Moving Average* (MA), model ini cocok digunakan untuk rangkaian data yang stasioner (Mishra et al., 2021). Secara umum, proses ARMA (p, q) memiliki p sebagai *Autoregressive* dan q sebagai *Moving Average* (AYIK & ERKAL, 2021). Sebuah deret waktu (Y_t) dikatakan mengikuti proses rata-rata bergerak autoregresif dengan orde p dan q , ARMA (p, q), berproses jika:

$$Y_t = \mu + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

Model ini dapat berupa campuran dari model AR dan MA di atas (Abonazel & Abd-Elftah, 2019; Hal, 2021; Hassan, 2020).

2.7 Model Autoregressive Integrated Moving Average (ARIMA)

Dalam data non-stasioner, model ARMA (p, q) dikenal sebagai *Autoregressive Integrated Moving Average* (ARIMA) (p, d, q), yang mengaplikasikan operasi perbedaan orde d untuk menjadikannya stasioner. Model ARIMA (p, d, q) memiliki tiga parameter: AR (p) untuk urutan

proses autoregresif, I (d) untuk urutan perbedaan agar data stasioner jika tidak stasioner, dan MA (q) untuk urutan proses rata-rata bergerak (Mathew & Murugesan, 2020; Mishra et al., 2021; Wei & Banu, 2021; Yonar, & Tekindal, 2020). Parameter I diterapkan saat data tidak stasioner, dengan d=0 untuk stasioner dan d=1 untuk selisih pertama. Model ARIMA memperluas ARMA dengan memasukkan diferensiasi untuk menangani deret tidak stasioner, contohnya, penerapan diferensiasi pertama untuk model ARIMA (p,1,q) (Ozturk & Ozturk, 2018).

$$Z_t = \mu + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

atau

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B) \varepsilon_t$$

- Z_t : nilai deret waktu ke t yang sudah di diferensiasi
- $\phi_p(B)$: operator autoregresif = $1 - \phi_1(B) - \phi_2(B)^2 - \dots - \phi_p(B)^p$
- $\theta_q(B)$: operator rata-rata bergerak = $1 - \theta_1(B) - \theta_2(B)^2 - \dots - \theta_q(B)^q$
- $(1-B)^d$: operator diferensiasi yang diterapkan sebanyak d

2.8 Model Seasonal Autoregressive Integrated Moving Average (SARIMA)

SARIMA (*Seasonal Autoregressive Integrated Moving Average*) adalah pengembangan dari model ARIMA untuk data deret waktu dengan pola musiman. Model SARIMA dinyatakan sebagai (p,d,q)×(P,D,Q)^s, di mana p, d, q mewakili komponen-komponen non musiman dari model, dan (P,D,Q)^s adalah komponen musiman (Palma, 2016). Dalam peramalan jangka panjang menggunakan SARIMA, hasil peramalan bergantung pada pola musiman terbaru, dengan komponen modifikasi aditif yang cenderung menurun menuju nol secara eksponensial seiring bertambahnya jangka waktu peramalan (Diksa, 2022). Rumus umum untuk SARIMA (*Seasonal Autoregressive Integrated Moving Average*) ditentukan dengan mempertimbangkan jumlah periode musiman (S) dalam model, yaitu sebagai berikut:

$$\phi_p(B)(\Phi_P B^S 1-B)^d (1-B^S)^D Z_t = \theta_q(B) \Theta_Q(B^S) \varepsilon_t$$

- Z_t : pengamatan pada waktu ke-t
- $\phi(B)$: operator autoregresif = $1 - \phi_1(B) - \dots - \phi_p(B)^p$
- $\Phi_P B^S$: operator autoregresif musiman = $(1 - \Phi_1 B^S - \dots - \Phi_P B^{PS})$
- $(1 - B)^d$: orde diferensiasi non-musiman
- $(1 - B^S)^D$: orde diferensiasi musiman
- $\theta(B)$: operator rata-rata bergerak = $1 - \theta_1(B) - \dots - \theta_q(B)^q$
- $\Theta(B^S)$: operator rata-rata bergerak musiman = $(1 - \Theta_1 B^S - \dots - \Theta_Q B^{QS})$
- ε_t : residual ketika waktu ke-t

2.9 Stasioneritas dan Nonstasioneritas

Pemodelan ARIMA memerlukan deret waktu yang stasioner agar peramalan dapat diandalkan. Deret stasioner memiliki tiga sifat utama yaitu mean konstan, varian konstan, dan kovariansi konstan tergantung pada interval waktu antar nilai. Suatu deret stasioner (juga disebut sebagai "white noise process") lebih mudah untuk dianalisis karena dapat dimodelkan dengan lebih sedikit parameter. Meskipun bisa berfluktuasi, deret tersebut akan selalu kembali ke *mean* konstan dan dengan demikian lebih mudah untuk diprediksi (Smith et al., 2023). Stasioneritas dapat dinilai melalui stasioneritas rata-rata dan varian. Uji *Augmented Dickey-Fuller* (ADF) digunakan untuk mengidentifikasi adanya akar unit dan menentukan apakah deret waktu perlu didiferensiasi untuk mencapai stasioneritas. Untuk stasioneritas varian, metode *Box-Cox* dapat digunakan, dengan nilai lambda (λ) melebihi satu menunjukkan data stasioner dalam varian (Pangaribuan et al., 2023; Panjaitan et al., 2018; Purnama, 2021).

Data deret waktu tidak stasioner didasari dua alasan yaitu apabila terjadi perubahan varians dari waktu ke waktu, yang sering bisa diperbaiki dengan menggunakan transformasi log dan tren yang naik atau turun, yang bisa dihilangkan dengan mengambil perbedaan antara nilai saat ini dan nilai sebelumnya ($Y_t - Y_{t-1}$). Untuk data yang memiliki kestasioneran lemah, diferensiasi kedua mungkin diperlukan untuk membuat deret waktu menjadi stasioner, tetapi diferensiasi ketiga dan

seterusnya jarang terjadi. Sebuah deret waktu dianggap stasioner secara kuat jika distribusi probabilitasnya tetap sama tanpa ada perubahan saat bergeser dalam waktu (Smith et al., 2023).

2.10 Plot ACF & PACF

Plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) membantu dalam identifikasi model ARIMA untuk analisis deret waktu. Grafik ACF menunjukkan korelasi antara nilai deret waktu dan nilai sebelumnya, sedangkan grafik PACF menunjukkan korelasi yang tidak dijelaskan oleh nilai-nilai antara dua titik waktu. Pola korelasi signifikan pada kedua plot mengindikasikan pola autokorelasi dalam data, penting untuk pemodelan ARIMA. *P-value* yang tinggi dapat menandakan kompleksitas model yang lebih besar, sehingga pemilihan parameter *p*, *d*, dan *q* harus tepat. Menggabungkan informasi dari kedua plot membantu menentukan parameter untuk model ARIMA yang akurat (Pangaribuan et al., 2023).

2.11 Pengukuran Akurasi Peramalan

Mean Absolute Percentage Error (MAPE) adalah metrik yang sering digunakan untuk menilai akurasi peramalan. MAPE mengukur persentase kesalahan prediksi relatif terhadap nilai sebenarnya dan menghasilkan rata-rata persentase kesalahan absolut. Ini sangat berguna untuk membandingkan data dengan interval waktu yang berbeda. Nilai MAPE yang lebih kecil menunjukkan akurasi peramalan yang lebih baik. MAPE membantu dalam menilai ketepatan model peramalan dan memilih model terbaik untuk peramalan masa depan (Diksa, 2022). Secara Matematis, MAPE dapat ditulis sebagai berikut:

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{z(t) - \hat{z}(t)}{z(t)} \right| \right) \times 100$$

- z_t : nilai observasi pada waktu ke-*t*
- \hat{z}_t : nilai peramalan pada waktu ke-*t*
- n* : banyaknya observasi.

Model yang baik adalah model yang memiliki nilai MAPE sesuai kriteria pada tabel berikut (Syam, 2022). Berikut kriteria kemampuan peramalan pada nilai MAPE.

Tabel 1. Kriteria Nilai MAPE

Nilai MAPE	Kriteria
<10%	Sangat baik
10 – 20%	Baik
20 – 50%	Cukup
>50%	Buruk

3. METODE PENELITIAN

Jenis penelitian ini adalah pendekatan kombinasi (*mixed methods*), yang menggabungkan metode kuantitatif dan kualitatif untuk mendapatkan gambaran yang lebih komprehensif dibandingkan dengan pendekatan tunggal (Purwanza et al., 2022; Vebrianto et al., 2020). Penelitian ini menerapkan metode *Autoregressive Integrated Moving Average* (ARIMA) untuk meramalkan jumlah produksi kelapa sawit di PTPN Kebun Sukamaju. Metode ARIMA digunakan dalam analisis deret waktu untuk memproyeksikan produksi tanaman kelapa sawit di lokasi tersebut. Metode ini memungkinkan penggunaan data historis untuk mengembangkan model peramalan yang dapat digunakan untuk meramalkan produksi masa depan.

Penelitian ini bertujuan menerapkan teknik peramalan yang tepat untuk mendukung pengambilan keputusan (Fauziah et al., 2019). Metode *Autoregressive Integrated Moving Average* (ARIMA) digunakan untuk meramalkan produksi kelapa sawit di PTPN Kebun Sukamaju dengan memanfaatkan data historis dan informasi terkini untuk menghasilkan peramalan yang akurat (Henrique et al., 2023; Ishak et al., 2023). ARIMA memiliki fleksibilitas untuk diterapkan pada berbagai jenis data deret waktu, diantaranya data yang menunjukkan musiman, variasi acak, dan tren (Pangaribuan et al., 2023). ARIMA juga sering digunakan ketika memperkirakan deret waktu yang non stasioner (AYIK & ERKAL, 2021; Yonar et al., 2020). ARIMA efektif untuk peramalan

jangka pendek karena akurasi yang tinggi dan kemampuannya menemukan hubungan statistik kuat antara variabel peramalan dan variabel yang diramal (Salwa et al., 2018). Dalam analisis produksi kelapa sawit, ARIMA digunakan untuk mengevaluasi pola data historis dan menghasilkan proyeksi nilai produksi di masa mendatang sebagai dasar pengambilan keputusan dan perencanaan manajemen operasional.

Penelitian ini dilakukan di PT Perkebunan Nusantara Kebun Sukamaju, anak perusahaan Kerja Sama Operasi (KSO) PTPN III (Persero), yang merupakan Badan Usaha Milik Negara (BUMN) di sektor agroindustri. Fokus utama perusahaan adalah produksi kelapa sawit dan minyak kelapa sawit, berkontribusi signifikan terhadap industri kelapa sawit nasional dan ekonomi Indonesia melalui ekspor komoditas utama. Peramalan produksi yang akurat diperlukan untuk memaksimalkan operasional perusahaan, yang berlokasi di Malinggut-Neglasari, Warnajati, Kecamatan Cibadak, Kabupaten Sukabumi, Jawa Barat 4335.

Penelitian ini menggunakan data primer dan sekunder untuk menghasilkan analisis yang komprehensif. Data primer diperoleh melalui wawancara dan observasi langsung, memberikan informasi rinci dan konteks operasional. Data sekunder, berupa catatan produksi bulanan kelapa sawit dari PTPN Kebun Sukamaju periode 2016-2023, dianalisis untuk mengidentifikasi tren dan pola produksi. Penggabungan kedua jenis data ini diharapkan memberikan wawasan mendalam tentang dinamika produksi kelapa sawit di Kebun Sukamaju. Fokus penelitian ini adalah pada data produksi kelapa sawit, dengan model ARIMA digunakan untuk meramalkan produksi 6-12 bulan ke depan berdasarkan pola dan tren data bulanan.

3.1 Teknik Pengumpulan Data

Penelitian ini menggunakan beberapa teknik pengumpulan data, diantaranya yaitu observasi langsung, wawancara, dokumentasi dan tinjauan kepustakaan.

1) Observasi

Observasi lapangan dilakukan untuk memantau proses produksi kelapa sawit di PTPN Kebun Sukamaju, mencakup kondisi lahan, perawatan tanaman, dan panen. Observasi ini memberikan gambaran tentang faktor-faktor yang mempengaruhi produksi kelapa sawit, membantu identifikasi aspek penting dalam manajemen kebun dan operasional.

2) Wawancara

Peneliti mewawancarai mandor, pemanen, dan staf administrasi di PTPN Kebun Sukamaju untuk mendapatkan informasi tentang praktik perkebunan, tantangan, dan faktor yang memengaruhi produksi. Wawancara ini memperluas pemahaman tentang konteks penelitian.

3) Dokumentasi

Pengumpulan data dilakukan dengan mengakses catatan produksi kelapa sawit di PTPN Kebun Sukamaju dari periode 2016-2023. Data historis ini penting untuk penerapan metode ARIMA dalam peramalan berdasarkan deret waktu.

4) Kepustakaan

Kepustakaan dilakukan dengan meninjau jurnal dan riset terkait untuk mengutip penelitian sebelumnya serta jurnal nasional dan internasional yang relevan dengan tema penelitian.

3.2 Teknik Analisis Data

Pendekatan umum ARIMA melibatkan empat langkah proses, yakni mengidentifikasi model, melakukan estimasi parameter, melakukan pemeriksaan diagnostik, dan melakukan peramalan (GC & JunHo, 2020).

3.3 Identifikasi Model

Identifikasi model bertujuan untuk menentukan stasioneritas data deret waktu produksi kelapa sawit. Tahap ini melibatkan pemeriksaan stasioneritas menggunakan uji *Augmented Dickey-Fuller* (ADF) atau analisis plot deret waktu. Data dianggap stasioner jika nilai p (probabilitas) dari uji ADF kurang dari 0,05, batas signifikansi maksimum (Prasetyono & Anggraini, 2021). Selain itu, plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) digunakan untuk

memeriksa kestasioneran; data dikatakan stasioner jika lag pada ACF dan PACF tidak melebihi 3 (Prasetyono & Anggraini, 2021). Jika data tidak stasioner, transformasi seperti diferensiasi diperlukan. Selanjutnya, identifikasi model ARIMA dilakukan melalui analisis plot ACF dan PACF dari data yang telah distasionerkan untuk menentukan parameter autoregresif dan rata-rata bergerak yang tepat untuk peramalan.

3.4 Estimasi Parameter

Dalam tahap estimasi parameter pada pendekatan ARIMA, dilakukan perhitungan nilai-nilai parameter model yang optimal dengan memilih model yang memiliki nilai terendah dari *Akaike's Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC) (Mokorimban et al., 2021).

3.5 Uji Diagnostik

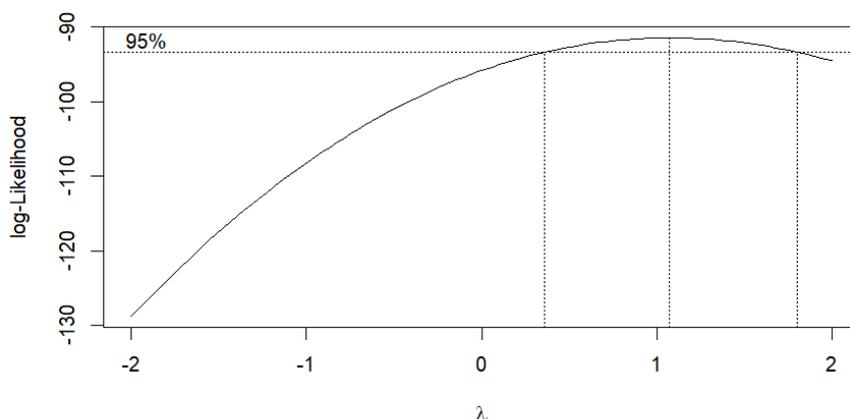
Uji diagnostik dilakukan untuk memverifikasi kecocokan dan kedekatan model ARIMA dengan data yang mencakup analisis residu untuk menentukan apakah ada pola atau struktur tertentu (*white noise*) yang tersisa dalam model. Uji *white noise* pada residu dilakukan dengan menggunakan uji *Ljung-Box*, pengujian ini mengasumsikan bahwa residu harus bersifat *white noise* (tidak memiliki pola atau autokorelasi). Residual dianggap memenuhi asumsi *white noise* jika *p-value* uji *Ljung-Box* lebih besar dari tingkat signifikansi *alpha* (α) yang ditentukan, yaitu 0,05 (Nurfadila & Ilham, 2020). Dengan kata lain, jika *p-value* lebih besar dari 0,05 maka dapat dikatakan residual telah mencapai tingkat *white noise* yang berarti model ARIMA yang dibangun berhasil menangkap pola dan ketergantungan data.

3.6 Peramalan

Pada tahap peramalan, model dengan parameter paling efisien diterapkan untuk memprediksi jumlah produksi kelapa sawit di masa depan. Selain itu evaluasi kinerja model peramalan perlu dilakukan untuk menilai akurasi prediksi, hal ini dapat dilakukan dengan menggunakan metrik seperti *Mean Absolute Percentage Error* (MAPE). Dalam penelitian ini, untuk mengimplementasikan metode ARIMA dalam analisis dan ramalan produksi kelapa sawit, perangkat lunak statistik yang digunakan yaitu *Software R-Studio*.

4. HASIL DAN PEMBAHASAN

Berdasarkan uji Box-Cox, nilai lambda (λ) adalah 1.070707, mendekati 1. Ini menunjukkan bahwa data tidak memerlukan transformasi besar, karena nilai lambda yang mendekati 1 menunjukkan data sudah cukup sesuai untuk analisis lebih lanjut. Meskipun nilai lambda sedikit lebih tinggi dari 1, menunjukkan bahwa transformasi pangkat dengan eksponen 1.070707 bisa sedikit memperbaiki normalitas dan stabilitas varians, transformasi besar tidak diperlukan. Transformasi kecil mungkin hanya memberikan sedikit peningkatan dalam normalisasi data, sehingga data dapat digunakan untuk analisis lebih lanjut dengan atau tanpa transformasi kecil tersebut.



Gambar 2. Plot Box-Cox

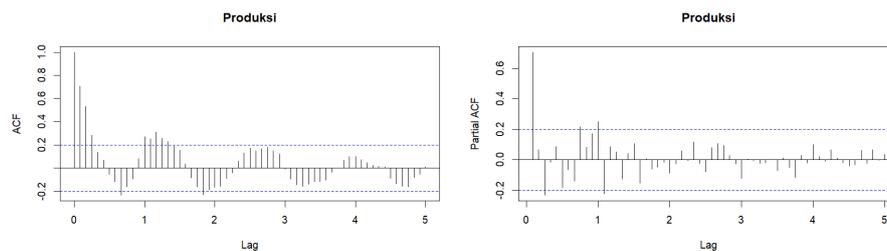
4.1 Uji Augmented Dickey-Fuller

Tabel 2. Uji Augmented Dickey-Fuller

Dickey-Fuller	Lag Order	P-Value	Alternatif Hipotesis
-3,9162	4	0,01644	Stasioner

Berdasarkan uji *Augmented Dickey-Fuller* (ADF), nilai statistik Dickey-Fuller adalah -3,9162 dengan *p-value* 0,01644. Karena *p-value* 0,01644 < 0,05, hipotesis nol tentang adanya akar unit dapat ditolak, menunjukkan bahwa data produksi sudah stasioner pada tingkat signifikansi 5%. Data stasioner merupakan syarat penting untuk analisis time series dan pemodelan ARIMA, sehingga data ini siap digunakan untuk analisis lebih lanjut.

4.2 Plot ACF dan PACF

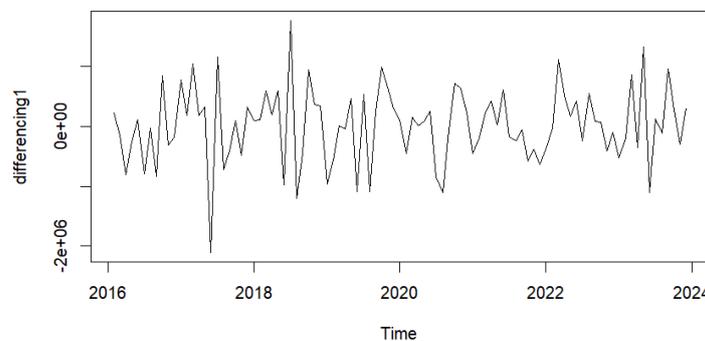


Gambar 3. Plot ACF dan PACF Data Produksi

Berdasarkan plot *Autocorrelation Function* (ACF), data produksi tidak sepenuhnya stasioner karena autokorelasi signifikan terlihat hingga lebih dari lag 3. Pola autokorelasi yang menurun perlahan dan menunjukkan osilasi menunjukkan adanya komponen musiman atau tren dalam data. Untuk memastikan kestasioneran, diperlukan diferensiasi tambahan atau transformasi untuk menghilangkan tren atau komponen musiman tersebut, agar data memenuhi asumsi stasioneritas yang penting dalam analisis time series dan pemodelan ARIMA.

4.3 Plot Data Produksi Hasil Diferensiasi

Plot: Data Produksi Kelapa Sawit PTPN Kebun Sukamaju



Gambar 4. Data Produksi Hasil Diferensiasi

Berdasarkan gambar diatas, setelah dilakukan proses diferensiasi kita dapat melihat bahwa pola data produksi kelapa sawit sudah mendekati garis rata-rata sehingga dapat menunjukkan kestasioneran data.

4.3 Uji Augmented Dickey-Fuller Hasil Diferensiasi

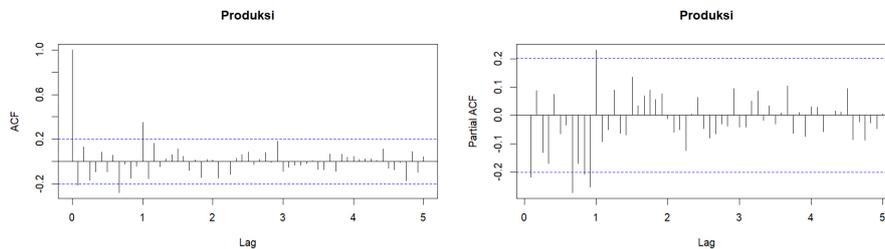
Tabel 3. Uji Augmented Dickey-Fuller Data Produksi (Diferensiasi)

Dickey-Fuller	Lag Order	P-Value	Alternatif Hipotesis
-4,7391	4	0,01	Stasioner

Sumber: Software R-Studio Versi 4.3.3

Berdasarkan uji *Augmented Dickey-Fuller* (ADF) pada data yang telah didiferensiasi, nilai statistik Dickey-Fuller adalah $-4,7391$ dengan lag order 4 dan $p\text{-value}$ 0,01. Karena $p\text{-value}$ ini lebih kecil dari 0,05, hal ini menunjukkan bahwa data yang telah didiferensiasi sekarang stasioner dengan tingkat kestasioneran yang lebih tinggi dibandingkan sebelum diferensiasi.

4.4 Plot ACF & PACF Hasil Diferensiasi



Gambar 5. Plot ACF dan PACF Data Produksi Hasil Diferensiasi

Pada plot *Autocorrelation Function* (ACF) ACF dan *Partial Autocorrelation Function* (PACF) diatas dapat dilihat bahwa tidak ada autokorelasi yang signifikan lebih dari 3, hal ini memastikan bahwa data sudah stasioner dan dapat dilanjutkan pada tahap selanjutnya. Plot ACF menunjukkan autokorelasi pada berbagai lag, sementara PACF menunjukkan autokorelasi parsial setelah mengendalikan pengaruh lag sebelumnya.

4.5 Identifikasi Model

Berdasarkan plot ACF dan PACF diatas dapat diidentifikasi model ARIMA musiman yang sesuai untuk data dengan pola non-musiman yang telah dilakukan diferensiasi ($d = 1$) dan tidak ada pola musiman yang dideferensiasi ($D = 0$). Berdasarkan autokorelasi signifikan pada lag 1, 2 dan 3 serta pola musiman, beberapa model ARIMA musiman yang diusulkan adalah ARIMA $(0,1,1)(1,0,1)[12]$, $(0,1,2)(1,0,1)[12]$, $(0,1,3)(1,0,1)[12]$, $(1,1,0)(1,0,1)[12]$, $(1,1,1)(1,0,1)[12]$, $(1,1,2)(1,0,1)[12]$, $(1,1,3)(1,0,1)[12]$, $(2,1,1)(1,0,1)[12]$, $(2,1,2)(1,0,1)[12]$, $(2,1,3)(1,0,1)[12]$. Model-model tersebut mengombinasikan komponen AR, MA, dan musiman yang berbeda untuk mengatasi autokorelasi dan pola musiman dalam data.

4.6 Estimasi Parameter

Dalam tahap estimasi parameter, dilakukan analisis terhadap parameter-parameter model ARIMA yang telah dipilih untuk memastikan bahwa model tersebut mampu merepresentasikan data dengan akurat. Berdasarkan data estimasi parameter yang diberikan, berikut adalah detail dari hasil estimasi parameter untuk model ARIMA yang dimodelkan.

Tabel 4. Model ARIMA Hasil Identifikasi

No	Model	AIC	AICc	BIC	MAE
1	$(0,1,1)(1,0,1)[12]$	2794,99	2795,44	2805,21	436877,7
2	$(0,1,2)(1,0,1)[12]$	2796,6	2797,27	2809,36	430370,5
3	$(0,1,3)(1,0,1)[12]$	2787,88	2788,84	2803,2	388287,5
4	$(1,1,0)(1,0,1)[12]$	2794,44	2794,88	2804,65	435169,6
5	$(1,1,1)(1,0,1)[12]$	2794,83	2795,5	2807,6	429489,6
6	$(1,1,2)(1,0,1)[12]$	2796,32	2797,27	2811,64	418765,3
7	$(1,1,3)(1,0,1)[12]$	2786,97	2788,25	2804,84	381526,7
8	$(2,1,1)(1,0,1)[12]$	2796,62	2797,57	2811,94	425244,9
9	$(2,1,2)(1,0,1)[12]$	2791,45	2792,74	2809,33	418615,4
10	$(2,1,3)(1,0,1)[12]$	2788,34	2790,01	2808,77	384156,1

Berdasarkan tabel diatas model ARIMA $(1,1,3)(1,0,1)[12]$ memiliki nilai AIC, AICc dan MAE terendah yaitu dengan nilai AIC sebesar 2786,97, AICc sebesar 2788,25, dan nilai MAE sebesar 381526,7, sedangkan untuk nilai BIC terendah berada pada model ARIMA $(0,1,3)(1,0,1)[12]$. Dengan demikian model terbaik dari tabel diatas adalah model ARIMA $(1,1,3)(1,0,1)[12]$ yang akan digunakan untuk peramalan.

Tabel 5. Estimasi Parameter

No	Komponen	Estimasi	P-Value
1	AR1	0,35673	0,1127
2	MA1	-0,59186	0,0070
3	MA2	0,10114	0,3976
4	MA3	-0,42944	0,0026
5	SAR1	0,161212	0,3955
6	SAR2	0,35340	0,0430

Model ARIMA(1,1,3)(1,0,1)[12] yang diestimasi menunjukkan bagaimana nilai saat ini dari deret waktu (Z_t), dipengaruhi oleh beberapa komponen masa lalu. Komponen *Autoregressive* satu periode sebelumnya (AR1) memberikan pengaruh positif sebesar 35,67%, meskipun pengaruh ini tidak signifikan secara statistik ($p = 0,1127$). Kesalahan pada satu periode sebelumnya (MA1) memberikan pengaruh negatif yang signifikan sebesar 59,19% ($p = 0,0070$). Kesalahan pada dua periode sebelumnya (MA2) memberikan pengaruh positif sebesar 10,11%, tetapi pengaruh ini tidak signifikan ($p = 0,3976$). Sebaliknya, kesalahan pada tiga periode sebelumnya (MA3) memberikan pengaruh negatif yang signifikan sebesar 42,94% ($p = 0,0026$).

Untuk komponen musiman, nilai satu tahun sebelumnya (SAR(1)) memiliki pengaruh positif sebesar 16,21%, namun pengaruh ini tidak signifikan ($p = 0,3955$). Kesalahan satu tahun sebelumnya (SMA(1)) memiliki pengaruh positif signifikan sebesar 35,34% ($p = 0,0430$). Komponen *differencing* $(1-B)$ dan $(1-B^{12})$ menunjukkan bahwa data telah di diferensiasi untuk menghilangkan tren dan pola musiman tahunan, menjadikannya stasioner. Secara keseluruhan, model ini menangkap dinamika kompleks dalam data dengan memperhitungkan pengaruh nilai dan kesalahan dari periode sebelumnya, baik dalam jangka pendek maupun jangka panjang.

4.7 Uji Diagnostik

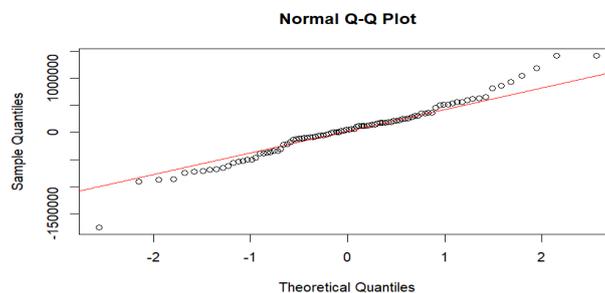
Uji Ljung-Box

Tabel 6. Uji Ljung-Box

Model	P-Value	Keterangan
(1,1,3)(1,0,1)[12]	0,1339	Tidak ada autokorelasi

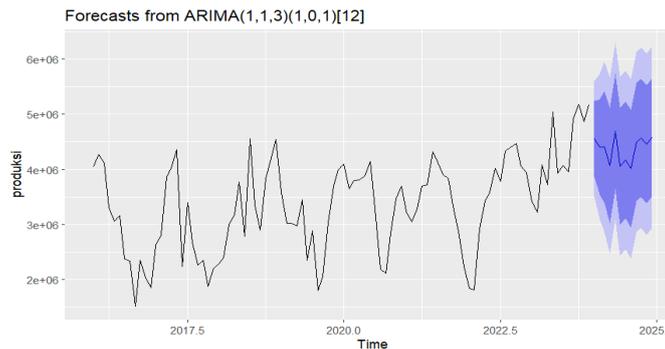
Sumber: Software R-Studio Versi 4.3.3

Uji *Ljung-Box* dengan *p-value* sebesar $0,1339 > 0,05$ pada residual model ARIMA(1,1,3)(1,0,1)[12] menunjukkan bahwa tidak ada autokorelasi yang signifikan dalam residual hingga lag ke-12. Ini berarti residual bersifat *white noise* atau acak, yang mengindikasikan bahwa model tersebut sudah memadai dalam menangkap pola yang ada dalam data. Oleh karena itu, model ARIMA(1,1,3)(1,0,1)[12] dianggap sudah sesuai dan tidak memerlukan modifikasi lebih lanjut.



Gambar 6. QQ-Plot

Berdasarkan gambar diatas sebagian besar titik pada QQ-plot berada dekat dengan garis diagonal. Dengan demikian, diagnostik plot memberikan bukti yang kuat bahwa model ARIMA(1,1,3)(1,0,1)[12] telah memenuhi asumsi *white noise* dan kenormalan residual, sehingga dapat digunakan untuk melakukan peramalan dengan hasil yang andal.



Gambar 7. Plot Hasil Peramalan

Dari tabel hasil peramalan diatas dapat dilihat bahwa produksi kelapa sawit PTPN Kebun Sukamaju 2024 akan mengalami penurunan dari tahun sebelumnya. Oleh karena itu perusahaan harus meningkatkan manajemen operasional untuk menghindari penurunan produksi tersebut.

Uji Keakuratan Peramalan

Tabel 7. Hasil Uji Keakuratan Model

MAPE	Kriteria
12,49368%	Baik

Sumber: Software R-Studio Versi 4.3.3

Nilai *Mean Absolute Percentage Error* (MAPE) sebesar 12.49% menunjukkan bahwa rata-rata kesalahan prediksi model adalah sekitar 12.49% dari nilai aktual. Dalam banyak aplikasi bisnis dan ekonomi, MAPE dengan nilai ini dianggap cukup baik. Secara umum, MAPE di bawah 10% dianggap sangat baik, antara 10-20% baik, 20-50% dapat diterima, dan di atas 50% buruk. Dengan MAPE sekitar 12.49%, model ini berada dalam kategori "baik".

5. KESIMPULAN

Kesimpulan menyajikan uraian singkat dari temuan penelitian yang paling penting memberikan kontribusi signifikan untuk memajukan bidang yang diteliti. Penilaian akhir tentang pentingnya temuan-temuan penelitian yang dilakukan dalam kaitannya dengan implikasinya. Indikasi keterbatasan penelitian. Menggunakan Palatino Linotype dengan 10pt, spasi 1.

DAFTAR PUSTAKA

Berdasarkan analisis dan pembahasan yang telah dilakukan, dapat disimpulkan beberapa hal penting terkait peramalan produksi kelapa sawit di PTPN Kebun Sukamaju. Data produksi kelapa sawit menunjukkan adanya pola musiman tahunan yang signifikan, dengan puncak produksi terjadi pada periode bulan Agustus-Oktober dan titik terendah pada bulan Februari-April. Setelah dilakukan proses diferensiasi, data menjadi stasioner dan memenuhi syarat untuk analisis *time series* lebih lanjut.

Berdasarkan identifikasi menggunakan plot ACF dan PACF, model ARIMA musiman terbaik yang dipilih adalah ARIMA(1,1,3)(1,0,1)[12] dengan nilai *Akaike Information Criterion* (AIC), *Corrected AIC* (AICc), dan *Mean Absolute Error* (MAE) terendah. Estimasi parameter pada model ini menunjukkan bahwa nilai produksi saat ini dipengaruhi oleh komponen autoregresif satu periode sebelumnya, kesalahan pada periode-periode sebelumnya, serta komponen musiman tahunan. Berdasarkan uji diagnostik, model ARIMA(1,1,3)(1,0,1)[12] memenuhi asumsi *white noise* dan kenormalan residual, sehingga dapat digunakan untuk peramalan dengan hasil yang andal. Hasil peramalan menggunakan model ARIMA(1,1,3)(1,0,1)[12] menunjukkan bahwa produksi kelapa sawit PTPN Kebun Sukamaju pada tahun 2024 akan mengalami penurunan dibandingkan tahun sebelumnya. Pengujian akurasi peramalan menggunakan *Mean Absolute Percentage Error* (MAPE)

menunjukkan nilai sebesar 12,49%, yang dikategorikan sebagai akurasi "baik" untuk aplikasi bisnis dan ekonomi.

SARAN

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa rekomendasi yang dapat disampaikan kepada pihak PTPN Kebun Sukamaju serta untuk penelitian selanjutnya terkait peramalan produksi kelapa sawit. Adapun rekomendasi tersebut adalah sebagai berikut:

1. PTPN Kebun Sukamaju sebaiknya meningkatkan manajemen operasional untuk mengatasi penurunan produksi yang diperkirakan pada tahun 2024.
2. Sebaiknya, secara berkala PTPN Kebun Sukamaju menerapkan metode peramalan produksi sehingga mempermudah perusahaan untuk menyusun perencanaan produksi dan manajemen operasional yang lebih efektif.
3. Bagi peneliti selanjutnya, disarankan menambahkan metode peramalan lain atau mengombinasikan beberapa metode untuk meningkatkan akurasi peramalan produksi kelapa sawit, sehingga memberikan proyeksi andal produksi kelapa sawit dimasa yang akan datang bagi pengambilan keputusan strategis perusahaan. Selain itu, peneliti juga disarankan untuk mengeksplorasi bidang yang lebih luas seperti manajemen sumber daya manusia yang berkaitan dengan produksi, guna memahami bagaimana faktor-faktor manusia dapat mempengaruhi efisiensi dan hasil produksi kelapa sawit.

DAFTAR PUSTAKA

- Abonazel, M. R., & Abd-Elftah, A. I. (2019). Forecasting Egyptian GDP using ARIMA models. *Reports on Economics and Finance*, 5(1), 35–47. <https://doi.org/10.12988/ref.2019.81023>
- Afeef, M., Ihsan, A., & Zada, H. (2018). Forecasting Stock Prices through Univariate ARIMA Modeling. *NUML International Journal of Business & Management ISSN*, 13(2), 2410–5392.
- AYIK, U., & ERKAL, G. (2021). Forecasting of Unemployment and Economic Growth for Turkey: ARIMA Model Application. *Turkish Journal of Forecasting*, 05(1), 12–22. <https://doi.org/10.34110/forecasting.917300>
- BPS. (2023). Ekspor Minyak Kelapa Sawit Menurut Negara Tujuan Utama, 2012-2022. Retrieved from <https://www.bps.go.id/id/statistics-table/1/MTAyNiMx/ekspor-minyak-kelapa-sawit-menurut-negara-tujuan-utama--2012-2022.html>
- Diksa, I. G. B. N. (2022). Forecasting the Existence of Chocolate with Variation and Seasonal Calendar Effects Using the Classic Time Series Approach. *Jurnal Matematika, Statistika Dan Komputasi*, 18(2), 237–250. <https://doi.org/10.20956/j.v18i2.18542>
- Edwards, R. B., Edmonds, E., Burke, P., Cameron, L., Falcon, W., Gollin, D., ... Suryadarma, D. (2019). Export agriculture and rural poverty: evidence from Indonesian palm oil. *Dartmouth College: Hanover, Germany*, 1–25.
- Fauziah, Ningsih, Y. I., & Setiarini, E. (2019). Jurnal Ilmiah Ekonomi dan Bisnis, 10(1): 61–67 Analisis Peramalan (Forecasting) Penjualan Jasa Pada Warnet Bulian City di Muara Bulian. *Jurnal Ilmiah Ekonomi Dan Bisnis*, 10(1), 61–67.
- GC Arun, & JunHo Yeo. (2020). Rice Production of Nepal in 2030: A Forecast using *Autoregressive Integrated Moving Average Model*. *Journal of South Asian Studies*, 25(4), 31–58. <https://doi.org/10.21587/jsas.2020.25.4.002>
- Hal, J. (2021). Penerapan Model SARIMA untuk Memprediksi Tingkat Inflasi di Indonesia *Jurnal Sains Matematika dan Statistika Penerapan Model SARIMA untuk Memprediksi Tingkat Inflasi di Indonesia*, (August). <https://doi.org/10.24014/jsms.v7i2.13168>
- Harahap, F., Leduc, S., Mesfun, S., Khatiwada, D., Kraxner, F., & Silveira, S. (2020). Meeting the bioenergy targets from palm oil based biorefineries: An optimal configuration in Indonesia. *Applied Energy*, 278(September), 115749. <https://doi.org/10.1016/j.apenergy.2020.115749>
- Hassan, H. M. (2020). Modelling GDP for Sudan using ARIMA. *SSRN Electronic Journal*, (101207). <https://doi.org/10.2139/ssrn.3630099>
- Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2023). Practical machine learning: Forecasting daily financial markets directions. *Expert Systems with Applications*, 233, 120840. <https://doi.org/10.1016/J.ESWA.2023.120840>

- Hidayatullah, T. (2023). Analisis Empiris Produksi Kelapa Sawit Terhadap Tingkat Kesejahteraan Petani. *Jurnal Budget : Isu Dan Masalah Keuangan Negara*, 8(1), 156–175. <https://doi.org/10.22212/jbudget.v8i1.152>
- Ishak, S. S., Abednego, M., Sari, D. M., Sabila, V. S., Khoirunnisa, K., Alvionita, M., & Muthoharoh, L. (2023). Indonesian Consumer Price Index Forecasting Using *Autoregressive Integrated Moving Average*. *International Journal of Electronics and Communications Systems*, 3(1), 33. <https://doi.org/10.24042/ijecs.v3i1.18252>
- Krishna, V. V., & Kubitza, C. (2021). Impact of oil palm expansion on the provision of private and community goods in rural Indonesia. *Ecological Economics*, 179(August 2020), 106829. <https://doi.org/10.1016/j.ecolecon.2020.106829>
- Kristanto, H., Tamsi, & Cuandra, F. (2022). Penerapan Manajemen Operasional dalam Meningkatkan Kinerja di Apple, Inc. *YUME : Journal of Management*, 5(3), 84–96. <https://doi.org/10.37531/yume.vxix.457>
- Kubitza, C., Krishna, V. V., Alamsyah, Z., & Qaim, M. (2018). The Economics Behind an Ecological Crisis: Livelihood Effects of Oil Palm Expansion in Sumatra, Indonesia. *Human Ecology*, 46(1), 107–116. <https://doi.org/10.1007/s10745-017-9965-7>
- Mahayana, I. B. B., Mulyadi, I., & Soraya, S. (2022). Peramalan Penjualan Helm dengan Metode ARIMA (Studi Kasus Bagus Store). *Inferensi*, 5(1), 45. <https://doi.org/10.12962/j27213862.v5i1.12469>
- Mathew, S., & Murugesan, R. (2020). Indian natural rubber price forecast—An *Autoregressive Integrated Moving Average* (ARIMA) approach. *Indian Journal of Agricultural Sciences*, 90(February), 418–422. <https://doi.org/https://doi.org/10.56093/ijas.v90i2.103067>
- Mgaya, J. F. (2019). Application of ARIMA models in forecasting livestock products consumption in Tanzania. *Cogent Food and Agriculture*, 5(1). <https://doi.org/10.1080/23311932.2019.1607430>
- Mishra, P., Yonar, A., Yonar, H., Kumari, B., Abotaleb, M., Das, S. S., & Patil, S. G. (2021). State of the art in total pulse production in major states of India using ARIMA techniques. *Current Research in Food Science*, 4, 800–806. <https://doi.org/10.1016/j.crfs.2021.10.009>
- Mokorimban, F. E., Nainggolan, N., & Langi, Y. A. R. (2021). Penerapan Metode *Autoregressive Integrated Moving Average* (ARIMA) dalam Model Intervensi Fungsi Step terhadap Indeks Harga Konsumen di Kota Manado. *D'Cartesian Jurnal Matematika Dan Aplikasi*, 10(2), 91–99.
- Nasution, A. S., & Wulansari, I. Y. (2019). Analyzing Impacts of Renewable Energy Directive (RED) on Crude Palm Oil (CPO) Export and Forecasting CPO Export from Indonesia to European Union (EU) for 2019–2020 Using ARIMA Intervention Analysis, 98(Icot 2019), 131–135. <https://doi.org/10.2991/icot-19.2019.28>
- Nurfadila, K., & Ilham Aksan. (2020). Aplikasi Metode Arima Box-Jenkins Untuk Meramalkan Penggunaan Harian Data Seluler. *Journal of Mathematics: Theory and Applications*, 2(1), 5–10. <https://doi.org/10.31605/jomta.v2i1.749>
- Ozturk, S., & Ozturk, F. (2018). Forecasting Energy Consumption of Turkey by Arima Model. *Journal of Asian Scientific Research*, 8(2), 52–60. <https://doi.org/10.18488/journal.2.2018.82.52.60>
- Palma, W. (2016). *Time Series Analysis*. (D. J. Balding, N. A. Cressie, G. M. Fitzmaurice, G. H. Givens, H. Goldstein, G. Molenberghs, ... J. L. Teugels, Eds.) (1st ed.). Hoboken, New Jersey: John Wiley & Sons, Inc.
- Pangaribuan, J. J., Fanny, F., Barus, O. P., & Romindo, R. (2023). Prediksi Penjualan Bisnis Rumah Properti Dengan Menggunakan Metode *Autoregressive Integrated Moving Average* (ARIMA). *Jurnal Sistem Informasi Bisnis*, 13(2), 154–161. <https://doi.org/10.21456/vol13iss2pp154-161>
- Panjaitan, H., Prahutama, A., & Sudarno, S. (2018). PERAMALAN JUMLAH PENUMPANG KERETA API MENGGUNAKAN METODE ARIMA, INTERVENSI DAN ARFIMA (Studi Kasus : Penumpang Kereta Api Kelas Lokal Ekonomi DAOP IV Semarang). *Jurnal Gaussian*, 7(1), 96–109. <https://doi.org/10.14710/j.gauss.v7i1.26639>
- Pathak, M. R., & Kapadia, J. M. (2021). Indian Stock Market Predictive Efficiency using the ARIMA Model. *Srusti Management Review*, 14(1), 10–15.
- Prasetyono, R. I., & Anggraini, D. (2021). Analisis Peramalan Tingkat Kemiskinan Di Indonesia Dengan Model Arima. *Jurnal Ilmiah Informatika Komputer*, 26(2), 95–110. <https://doi.org/10.35760/ik.2021.v26i2.3699>
- Purnama, D. I. (2021). Peramalan Curah Hujan Di Kabupaten Parigi Moutong Menggunakan Model *Seasonal Autoregressive Integrated Moving Average* (SARIMA). *Jurnal Ilmiah Matematika Dan Terapan*, 18(2), 136–147. <https://doi.org/10.22487/2540766x.2021.v18.i2.15652>
- Purwanza, S. W., Wardhana, A., Mufidah, A., Renggo, Y. R., Hudang, A. K., Setiawan, J., & Darwin. (2022). *Metodologi Penelitian Kuantitatif, Kualitatif dan Kombinasi*. Media Sains Indonesia.
- Rahim, N. F., Othman, M., & Sokkalingam, R. (2018). A Comparative Review on Various Method of Forecasting Crude Palm Oil Prices. *Journal of Physics: Conference Series*, 1123(1). <https://doi.org/10.1088/1742-6596/1123/1/012043>

- Rahimi, Z. H., & Khashei, M. (2018). A least squares-based parallel hybridization of statistical and intelligent models for time series forecasting. *Computers and Industrial Engineering*, 118, 44–53. <https://doi.org/10.1016/j.cie.2018.02.023>
- Ridwan Harimansyah, F., & Tukhas Shilul Imaroh. (2020). Aircraft Spare Parts Inventory Management Analysis on Airframe Product Using Continuous Review Methods. *Dinasti International Journal of Management Science*, 2(1), 81–90. <https://doi.org/10.31933/dijms.v2i1.528>
- Rizkya, I., Syahputri, K., Sari, R. M., Siregar, I., & Utaminingrum, J. (2019). *Autoregressive Integrated Moving Average (ARIMA) Model of Forecast Demand in Distribution Centre. IOP Conference Series: Materials Science and Engineering*, 598(1). <https://doi.org/10.1088/1757-899X/598/1/012071>
- Ruml, A., Chrisendo, D., Iddrisu, A. M., Karakara, A. A., Nuryartono, N., Osabuohien, E., & Lay, J. (2022). Smallholders in agro-industrial production: Lessons for rural development from a comparative analysis of Ghana's and Indonesia's oil palm sectors. *Land Use Policy*, 119(May), 106196. <https://doi.org/10.1016/j.landusepol.2022.106196>
- Salwa, N., Tatsara, N., Amalia, R., & Zohra, A. F. (2018). Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average). *Journal of Data Analysis*, 1(1), 21–31. <https://doi.org/10.24815/jda.v1i1.11874>
- Santika, T., Wilson, K. A., Budiharta, S., Law, E. A., Poh, T. M., Ancrenaz, M., ... Meijaard, E. (2019). Does oil palm agriculture help alleviate poverty? A multidimensional counterfactual assessment of oil palm development in Indonesia. *World Development*, 120, 105–117. <https://doi.org/10.1016/j.worlddev.2019.04.012>
- Selvam, S. K., Rajendran, C., & Sankaralingam, G. (2024). A linear programming-based bi-objective optimization for forecasting short univariate time series. *Decision Analytics Journal*, 10(January), 100400. <https://doi.org/10.1016/j.dajour.2024.100400>
- Setiawan, D. A., Wahyuningsih, S., & Goejantoro, R. (2019). Peramalan Produksi Kelapa Sawit Menggunakan Winter's dan Pegel's Exponential Smoothing dengan Pemantauan Tracking Signal. *Jambura Journal of Mathematics*, 2(1), 1–14. <https://doi.org/10.34312/jjom.v2i1.2320>
- Siami-Namini, S., & Namin, A. S. (2018). Forecasting Economics and Financial Time Series: ARIMA vs. LSTM, 1–19. Retrieved from <http://arxiv.org/abs/1803.06386>
- Smith, D. C., Thumm, E. B., Anderson, J., Kissler, K., Reed, S. M., Centi, S. M., ... Barton, A. J. (2023). Sudden Shift to Telehealth in COVID-19: A Retrospective Cohort Study of Disparities in Use of Telehealth for Prenatal Care in a Large Midwifery Service. *Journal of Midwifery and Women's Health*, 8, 1–12. <https://doi.org/10.1111/jmwh.13601>
- Syam, A. R. P. (2022). Application of the Autoregressive Integrated Moving Average Exogenous (ARIMAX) with Calendar Variation Effect Method for Forecasting Chocolate Data in Indonesia and the United States. *Jurnal Matematika, Statistika Dan Komputasi*, 18(2), 224–236. <https://doi.org/10.20956/j.v18i2.18460>
- Vebrianto, R., Thahir, M., Putriani, Z., Mahartika, I., Ilhami, A., & Diniya. (2020). Mixed methods Research: Trends and Issues in Research Methodology. *Bedelau: Journal of Education and Learning*, 1(2), 63–73. <https://doi.org/10.55748/bjel.v1i2.35>
- Wahjono, W. (2021). Peran Manajemen Operasional dalam Menunjang Keberlangsungan Kegiatan Perusahaan. *Jurnal Ilmiah Infokam*, 17(2), 114–120. <https://doi.org/10.53845/infokam.v17i2.302>
- Wei Yee, K., & Banu Samsudin, H. (2021). Comparison between Artificial Neural Network and ARIMA Model in Forecasting Palm Oil Price in Malaysia. *International Journal of Scientific Engineering and Science*, 5(11), 12–15. Retrieved from <http://ijkses.com/>
- Yani, T. A. R., Wahyuningsih, S., & Siringoringo, M. (2022). Optimasi Parameter Pemulusan Pada Metode Peramalan Double Exponential Smoothing Holt Menggunakan Golden Section (Studi Kasus : NPTT Provinsi Kalimantan Timur Tahun 2014-2019) Optimization of Smoothing Parameters in the Double Exponential Smoothing Holt. *Jurnal Eksponensial*, 13(1), 51–56. Retrieved from <http://jurnal.fmipa.unmul.ac.id/index.php/exponensial/article/view/880%0Ahttp://jurnal.fmipa.unmul.ac.id/index.php/exponensial/article/download/880/361>
- Yonar, H., Yonar, A., Tekindal, M. A., & Tekindal, M. (2020). Modeling and Forecasting for the number of cases of the COVID-19 pandemic with the Curve Estimation Models, the Box-Jenkins and Exponential Smoothing Methods. *Eurasian Journal of Medicine and Oncology*, 4(2), 160–165. <https://doi.org/10.14744/ejmo.2020.28273>
- Yonar, H., Yonar, A., Tekindal, M., Çevrimli, M. B., Alkan, H., İnanç, Z. S., ... Tekindal, M. A. (2020). Analyzing COVID-19 outbreak for Turkey and Eight Country with Curve Estimation Models, Box-Jenkins (ARIMA), Brown Linear Exponential Smoothing Method, Autoregressive Distributed Lag (ARDL) and SEIR Models.

Eurasian Journal of Veterinary Sciences, (Covid-19 Special Issue), 142–155.
<https://doi.org/10.15312/eurasianjvetsci.2020.304>

Yudi, Y. (2018). Peramalan Penjualan Mesin Industri Rumah Tangga Dengan Metode Fuzzy Time Series Ruey Chyn Tsaur. *Jurnal Informatika Kaputama (JIK)*, 2(1), 53–59. <https://doi.org/10.59697/jik.v2i1.432>

Zainul, M. (2019). *Buku Manajemen Operasional*. Deepublish (1st ed.). Yogyakarta: Penerbit Deepublish (Grup Penerbit CV BUDI UTAMA). Retrieved from www.deepublish.co.id