ISSN: 2339-2541
JURNAL GAUSSIAN, Volume 15, Nomor 2, Tahun 2026, Halaman 459 - 470
Online di: https://ejournal3.undip.ac.id/index.php/gaussian/

PERBANDINGAN MODEL SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE DAN ARTIFICIAL NEURAL NETWORK UNTUK MERAMALKAN JUMLAH PRODUKSI KOPI DI INDONESIA

Novia Ardani[1], Sri Wahyuningsih[1*], Desi Yuniarti[1], Meiliyani Siringoringo[1], M. Fathurahman[1]
[1]Program Studi Statistika, Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Mulawarman
***e-mail**: swahyuningsih@fmipa.unmul.ac.id

DOI: 10.14710/j.gauss.15.2.459-470

Article Info:
Received: 2026-08-06
Accepted: 2026-11-11
Available Online: 2026-11-25

Keywords:
Artificial Neural Network; Coffee; Forecasting; SARIMA

Abstract: The SARIMA model effectively forecasts seasonal and linear time series patterns, while ANN captures complex nonlinear patterns without relying on specific statistical assumptions. Indonesian coffee production data is suspected to exhibit both characteristics. This study compares SARIMA and ANN performance in forecasting Indonesian coffee production using two data-splitting schemes, 90:10 and 80:20. The best SARIMA model, SARIMA $(0,1,2)\ (0,1,0)^{12}$ was obtained at the 90:10 proportion with an RMSE of 0.30803, MAE of 0.13793, and MASE of 0.36332. The best ANN model, with a 5-neuron architecture, was obtained at the 80:20 proportion with an RMSE of 0.15138, MAE of 0.10235, and MASE of 0.39034. Given its lower error, ANN was selected as the best model, predicting Indonesian coffee production will rise gradually from January to July 2026 before declining.

1. PENDAHULUAN

Indonesia merupakan negara penghasil kopi terbanyak keempat di dunia, dan konsumsi kopi di dalam negeri tumbuh rata-rata 13,9% per tahun, jauh melampaui pertumbuhan konsumsi global (Paryanto, 2025). Di sisi lain, produksi kopi bersifat musiman dengan puncak panen pada Agustus–September, dan fluktuasinya tidak sepenuhnya beraturan (Nasirudin, Pindianti, Said, & Widodo, 2022). Kondisi ini menimbulkan tantangan bagi sektor perkebunan kopi, yaitu permintaan domestik yang meningkat pesat sementara pasokan berubah-ubah mengikuti musim dan sulit diperkirakan.

Peramalan jumlah produksi yang akurat diperlukan untuk menjawab tantangan tersebut. Karena data produksi kopi memiliki pola musiman dan fluktuasi yang tidak beraturan, metode yang digunakan perlu mampu menangkap pola linier, musiman, sekaligus kemungkinan pola nonlinier. Model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) mampu menangkap pola linier dan musiman, tetapi kurang mampu menangkap informasi nonlinier pada data (Hermawan, Cahyarani, Siregar, & Kartiasih, 2025). Sebaliknya, *Artificial Neural Networ*k (ANN) dapat menangkap hubungan nonlinier tanpa memerlukan asumsi stasioneritas (Panggabean & Sagala, 2021). Perbandingan keduanya pada data harga beras (Ngestisari, Susanto, & Mahatma, 2020) dan inflasi (Julianti, Ruhiat, & Rahayu, 2024) secara konsisten menunjukkan bahwa performa masing-masing model bergantung pada karakteristik data. Oleh karena itu, model terbaik untuk meramalkan produksi kopi perlu ditentukan melalui perbandingan langsung pada data produksi kopi.

Penelitian terdahulu tentang produksi kopi masih menggunakan satu pendekatan secara terpisah pada lingkup provinsi tertentu, baik ANN (Guntara, Santi, & Priyanto, 2025) maupun SARIMA (Nasirudin, Pindianti, Said, & Widodo, 2022), sehingga belum tersedia peramalan yang membandingkan kedua model di tingkat nasional. Berdasarkan hal tersebut, penelitian ini bertujuan menyediakan peramalan jumlah produksi kopi Indonesia (ribu ton),

dengan membandingkan performa model SARIMA dan ANN pada data periode Januari 2018–Desember 2025. Perbandingan dilakukan menggunakan indikator RMSE, MAE, dan MASE. Model terbaik kemudian digunakan untuk meramalkan produksi kopi Indonesia selama 12 bulan ke depan, yaitu Januari hingga Desember 2026.

2. TINJAUAN PUSTAKA

Periodogram merupakan pendekatan analisis deret waktu yang didasarkan pada asumsi bahwa data deret waktu tersusun dari kombinasi gelombang sinus dan kosinus dengan periode pengulangan yang berbeda-beda (Box, Jenkins, Reinsel, & Ljung, 2016). Nilai periodogram dapat ditemukan dengan mencari nilai frekuensi ke-m $\left(\omega_m\right)$ dan koefisien Fourier $\left(A_m\right)$ dan $\left(E_m\right)$ yang diperoleh dari persamaan (1) dan persamaan (2) sebagai berikut:

$$A_m = \begin{cases} \frac{1}{n}\left[\sum_{t=1}^{n} Y_t \cos\left(\omega_m t\right)\right], m = 0, m = \frac{n}{2}\ jika.n.genap \\ \frac{2}{n}\left[\sum_{t=1}^{n} Y_t \cos\left(\omega_m t\right)\right], m = 1,2,...,\left[\frac{(n-1)}{2}\right] \end{cases} \quad (1)$$

$$E_m = \frac{2}{n}\left[\sum_{t=1}^{n} Y_t \sin\left(\omega_m t\right)\right], m = 1,2,...,\left[\frac{(n-1)}{2}\right]$$

$$\omega_m = \frac{2\pi m}{n},\ m = 0,1,2,...,\frac{n}{2} \quad (2)$$

Menghitung nilai periodogram menggunakan persamaan (3) berikut:

$$I\left(\omega_m\right) = \begin{cases} nA_m^2, & m = 0 \\ \frac{n\left(A_m^2 + E_m^2\right)}{2}, m = 1,2,...,\left[\frac{(n-1)}{2}\right] & n.ganjil \\ nA_m^2, & m = \frac{n}{2} \end{cases} \quad (3)$$

Untuk menentukan periode musiman dapat menggunakan persamaan (4) berikut:

$$T^* = \frac{2\pi}{\omega_m} \quad (4)$$

Model ARIMA merupakan salah satu model permalan deret waktu yang populer karena kemampuannya menangani data tidak stasioner melalui proses diferensiasi. ARIMA merupakan pengembangan dari model *autoregressive* (AR) dan *moving average* (MA) dengan penambahan komponen *differencing* (I) (Box, Jenkins, Reinsel, & Ljung, 2016). Namun, dalam praktiknya, banyak data deret waktu yang tidak hanya mengandung tren, tetapi juga pola musiman. Untuk mengakomodasi hal tersebut, model ARIMA dikembangkan lebih lanjut menjadi *Seasonal* ARIMA (SARIMA) dengan menambahkan komponen musiman ke dalam model (Wei, 2006). Adapun model umum SARIMA dapat dilihat pada persamaan (5) yaitu:

$$\varphi_P(B^s)\phi_p(B)(1-B)^d(1-B^s)^D Y_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (5)$$

dengan:

Y_t : Data deret waktu pada waktu ke-t.

$\emptyset_p(B)$: Parameter *autoregressive* nonmusiman orde ke-p.
$\varphi_P(B^s)$: Parameter *autoregressive* musiman orde ke-P.
$\theta_q(B)$: Parameter *moving average* nonmusiman orde ke-q.
$\Theta_Q(B^s)$: Parameter *moving average* musiman orde ke-Q.
B : Operator *backward shift*, dengan $BY_t = Y_{t-1}$.
$(1-B)^d Y_t$: Operator *differencing* nonmusiman orde ke-d, dimana $Y_t - Y_{t-1}$.
$(1-B^s)^D Y_t$: Operator *differencing* musiman orde ke-D, dimana $Y_t - Y_{t-s}$.
d : Orde *differencing* nonmusiman.
D : Orde *differencing* musiman.
s : Jumlah periode musiman.
a_t : *Error* pada waktu ke-t yang diasumsikan mengikuti proses *white noise*

Estimasi parameter model SARIMA dilakukan menggunakan metode *maximum likelihood* (MLE), dengan asumsi *error* (a_t) berdistribusi normal, memiliki nilai rata-rata nol dan simpangan baku tertentu (σ_a^2). Fungsi *log-likelihood* yang digunakan adalah *likelihood* Gaussian bersyarat, dengan *n* adalah banyaknya residual efektif setelah *differencing.* Berdasarkan asumsi tersebut, fungsi *log-likelihood* dinyatakan pada persamaan (6) berikut:

$$l(\phi,\theta,\varphi,\Theta,\sigma_{a_t}^2 \mid Y_t) = -\frac{n}{2}\log 2\pi - \frac{n}{2}\log\sigma_{a_t}^2 - \frac{1}{2\sigma_{a_t}^2} S(\phi,\theta,\varphi,\Theta) \tag{6}$$

dengan $S(\phi,\theta,\varphi,\Theta)$ merupakan jumlah kuadrat *error* terhadap seluruh nilai parameternya, yang dinyatakan pada persamaan (7):

$$S(\phi,\theta,\varphi,\Theta) = \sum_{t=1}^{n}\left(Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \ldots - \Theta_Q a_{t-(Qs)}\right)^2 \tag{7}$$

dikarenakan parameter tersebut hanya berperan dalam komponen jumlah kuadrat pada fungsi *likelihood,* maka memaksimalkan nilai *likelihood* dapat dilakukan secara ekuivalen dengan meminimalkan fungsi jumlah kuadrat $S(\phi,\theta,\varphi,\Theta)$ *error* dengan asumsi *error* berdistribusi normal (Wei, 2006). Berdasarkan penaksiran tersebut, diperoleh nilai MLE untuk $\hat{\sigma}_a^2$ pada persamaan (8):

$$\hat{\sigma}_a^2 = \frac{\hat{S}(\hat{\phi},\hat{\theta},\hat{\varphi},\hat{\Theta})}{n} \tag{8}$$

Artificial neural network (ANN) merupakan pendekatan pembelajaran yang terinspirasi dari mekanisme jaringan saraf biologis, direpresentasikan sebagai model nonlinier yang tersusun atas *neuron-neuron* buatan yang saling terhubung dalam bentuk lapisan *input, hidden layer,* dan *output* (Kuntarini, 2024). Berdasarkan jumlah *hidden layer*-nya, ANN dibedakan menjadi *single layer perceptro n* (SLP) untuk masalah linier separable, dan *multilayer perceptron* (MLP) yang mampu menangani hubungan nonlinier (Ichwan & Alfarisyi, 2024). Kinerja ANN dipengaruhi oleh fungsi aktivasi yang memasukkan unsur nonlinieritas ke dalam jaringan. Fungsi aktivasi yang sering digunakan ANN sebagai berikut:

- Fungsi sigmoid biner, merupakan fungsi yang menghasilkan keluaran dalam rentang 0 hingga 1, dan umumnya digunakan ketika *output* yang diharapkan berupa bilangan riil pada interval tersebut. Fungsi sigmoid biner dinyatakan dengan persamaan (9):

$$f_1(x) = \frac{1}{1+e^{-x}} \text{ untuk } -\infty < x < \infty \text{ dengan } f_1'(x) = f_1(x)[1-f_1(x)] \tag{9}$$

- Fungsi linier,merupakan fungsi yang menghasilkan keluaran yang identik dengan masukannya, dan umumnya digunakan Ketika *output* jaringan yang diinginkan berupa bilangan riil dalam skala kontinu. Fungsi aktivasi linier dilihat pada persamaan (10):

$$f_3(x) = x \text{ untuk } -\infty < x < \infty \text{ dengan } f_3'(x) = 1 \tag{10}$$

Kinerja model peramalan dinilai berdasarkan tingkat *error* antara nilai prediksi dan nilai aktual, dengan model yang baik menghasilkan *error* sekecil mungkin. Beberapa ukuran evaluasi yang umum digunakan antara lain *root mean square error* (RMSE), *mean absolute error* (MAE), dan *mean absolute scaled error* (MASE). RMSE dihitung sebagai akar dari rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi (Syuhada & Setyawan, 2023) dinyatakan pada persamaan (11):

$$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n}(Y_t - F_t)^2} \tag{11}$$

MAE menghitung besarnya rata-rata penyimpangan absolut antara nilai aktual dan hasil prediksi, sehingga kemudahan interpretasinya dapat langsung menggambarkan tingkat akurasi model (Hendayanti & Nurhidayat, 2020) dinyatakan pada persamaan (12):

$$MAE = \frac{\sum_{i=1}^{n}|Y_t - F_t|}{n} \tag{12}$$

MASE sebagai alternatif MAPE, karena MAPE tidak dapat digunakan pada data bernilai nol/sangat kecil dan sensitive terhadap *outlier* dinyatakan pada persamaan (13):

$$MASE = \frac{\frac{1}{n}\sum_{t-1}^{n}|a_t|}{\frac{1}{n-1}\sum_{t-2}^{n}|Y_t - Y_{t-1}|} \tag{13}$$

dengan Y_t: nilai aktual, F_t: nilai prediksi, a_t: *error* pada periode ke-*t* dan *n*: banyaknya data pengamatan. Penelitian ini membandingkan hasil peramalan yang dihasilkan oleh kedua model pada data produksi kopi. SARIMA digunakan karena mampu menangkap pola musiman pada data secara eksplisit, sedangkan ANN digunakan karena tidak mensyaratkan adanya pola musiman dan fleksibel terhadap pola nonlinier.

3. METODE PENELITIAN

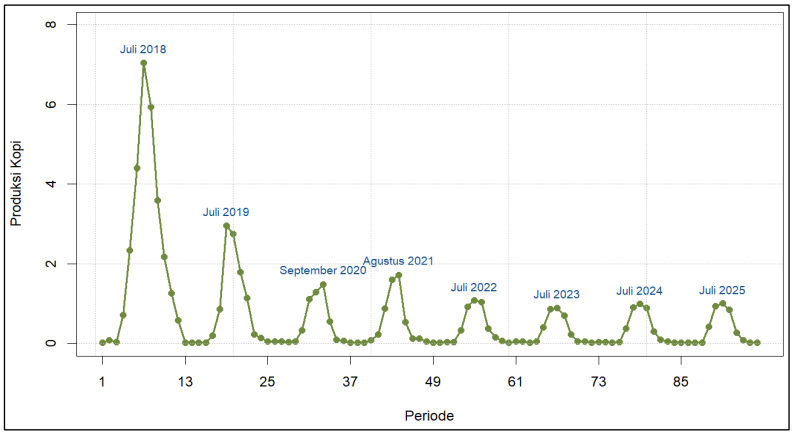
Penelitian ini menggunakan data sekunder berupa jumlah produksi kopi Indonesia dalam satuan ribu ton. Data diperoleh dari Badan Pusat Statistik (BPS) melalui tabel "Produksi Perkebunan Besar Bulanan Menurut Jenis Tanaman" yang dapat diakses pada (https://www.bps.go.id/id/statistics-table/2/NzYxIzI=/produksi-bulanan-perkebunan-besar.html). Data mencakup produksi kopi perkebunan besar di seluruh Indonesia dan berbentuk deret waktu bulanan Januari 2018 sampai Desember 2025 (96 observasi), sehingga tidak dilakukan pengolahan lanjutan. Variabel penelitian adalah jumlah produksi kopi di Indonesia, yang dimodelkan SARIMA dan ANN. Adapun langkah-langkah analisis data sebagai berikut:

1. Melakukan analisis statistika deskriptif pada data jumlah produksi kopi di Indonesia.
2. Membagi data menjadi data *training* dan *testing* dengan dua skema proporsi, yaitu 90:10 dan 80:20.
3. Melakukan analisis periodogram untuk mengidentifikasi pola musiman.
4. Melakukan pemodelan dengan model SARIMA pada masing-masing proporsi data, kemudian menghitung nilai evaluasi *error* menggunakan RMSE, MAE dan MASE.

5. Melakukan peramalan model SARIMA data jumlah produksi kopi di Indonesia pada masing-masing proporsi.
6. Melakukan pemodelan dengan model ANN pada masing-masing proporsi data, kemudian menghitung nilai evaluasi *error* menggunakan RMSE, MAE dan MASE.
7. Melakukan normalisasi data pada ANN denagn metode min-max lalu hasil peramalan dikembalikan ke satuan ribu ton melalui inverse transform.
8. Melakukan peramalan model ANN data jumlah produksi kopi di Indonesia pada masing-masing proporsi.
9. Membandingkan hasil evaluasi *error* permalan dari model terbaik masing-masing model untuk menentukan model dengan performa terbaik.

4. HASIL DAN PEMBAHASAN

Data yang digunakan adalah data bulanan jumlah produksi kopi di Indonesia periode Januari 2018 hingga Desember 2025, bersumber dari BPS. Grafik deret waktu data ditunjukan pada Gambar 1 berikut:



Gambar 1. Grafik deret waktu jumlah produksi kopi di Indonesia periode Januari 2018 hingga Desember 2025.

Gambar 1 menunjukkan pola musiman yang berulang setiap tahun. Puncak produksi tertinggi terjadi pada juli 2018, sedangkan titik terendah terjadi pada awal tahun (Januari-Maret). Pola ini berulang secara konsisten pada tahun-tahun berikutnya dan mengindikasikan adanya musiman dalam data. Data kemudian dibagi secara kronologis menjadi data *training* dan *testing* dengan dua skema proporsi, yaitu 90:10 dan 80:20. Kedua skema ini menguji konsistensi model dalam mengenali pola musiman dan tren produksi. Pada proporsi 90:10, data *training* mencakup 86 bulan (Januari 2018–Februari 2025) dan data *testing* mencakup 10 bulan (Maret–Desember 2025). Pada proporsi 80:20, data *training* mencakup 77 bulan (Januari 2018–Mei 2024) dan data *testing* mencakup 19 bulan (Juni 2024–Desember 2025).

Periodogram digunakan untuk mengecek pola musiman pada data jumlah produksi kopi di Indonesia. Periodogram dihitung pada data *training* untuk mengecek pola musiman pada data jumlah produksi kopi di Indonesia. Hasil analisis periodogram pada proporsi 90:10 menunjukkan nilai periodogram tertinggi terletak pada frekuensi ke-7, yaitu sebesar 36,15762, dengan frekuensi Fourier sebesar 0,51142. Nilai tersebut kemudian digunakan untuk menghitung periode musiman sebagai berikut:

$$T^* = \frac{2\pi}{\omega_7} = \frac{2\times 3{,}14159}{0{,}51142} = 12{,}28575 \approx 12 \qquad (14)$$

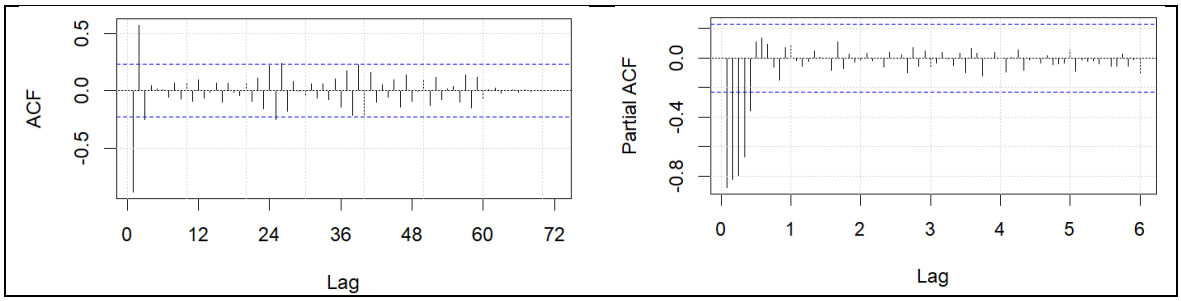
dari hasil perhitungan persamaan (14) tersebut, dapat diketahui dengan proporsi 90:10, pola musiman data jumlah produksi kopi di Indonesia berulang setiap 12 periode atau setara

dengan 12 bulan. Analisis periodogram juga dilakukan pada proporsi 80:20. menunjukkan nilai periodogram tertinggi berada pada frekuensi ke-6 sebesar 25,73703, dengan nilai frekuensi Fourier sebesar 0,48960. Periode musiman kemudian dihitung sebagai berikut:

$$T^* = \frac{2\pi}{\omega_6} = \frac{2 \times 3{,}14159}{0{,}48960} = 12{,}83333 \quad (15)$$

Puncak periodogram pada proporsi 80:20 berada di m = 6 dengan periode 12,83 bulan, mendekati siklus tahunan. Karena itu, periode musiman ditetapkan 12 bulan berdasarkan siklus kalender dan pola ACF pada *lag* 12, 24, dan 36 (Gambar 2).

Sebelum model SARIMA dibentuk, terlebih dahulu dilakukan pengujian stasioneritas data dari sisi varians dan rata-rata melalui transformasi Box-Cox serta uji ADF. Transformasi Box-Cox menghasilkan nilai λ sebesar 0,99997 (≈1), yang mengindikasikan bahwa data sudah stasioner dalam varians. Meski demikian, data belum stasioner dalam rata-rata karena pola musiman masih terlihat, sebagaimana terlihat pada Gambar 1. Oleh kerena itu, dilakukan *differencing* nonmusiman orde pertama (*d*=1) serta *differencing* musiman orde 12 (*D*=1) karena pola musiman pada *lag* 12,24, dan 36 masih belum stasioner. Setelah kedua proses *differencing* tersebut, data telah stasioner sepenuhnya, baik untuk komponen nonmusiman maupun musiman, yang ditunjukkan oleh pola *cut off* pada Gambar 2.



Gambar 2. Grafik ACF dan PACF data jumlah produksi kopi di Indonesia periode Januari 2018 hingga Februari 2025.

Berdasarkan Gambar 2, dari grafik ACF, nilai yang signifikan terlihat pada *lag* 1-3 lalu *cuts off* setelahnya, menunjukkan orde MA nonmusiman (*q*=3), sementara pada *lag* musiman tidak signifikan (*Q*=0). Pada grafik PACF, nilai signifikan muncul di *lag* 1-5 menunjukkan orde AR nonmusiman (*p*=5), dan *lag* musiman juga tidak signifikan (*P*=0). Berdasarkan kombinasi orde tersebut, diperoleh 23 model SARIMA sementara seperti pada Tabel 1:

Tabel 1. Model SARIMA Sementara Proporsi 90:10

Model Sementara SARIMA 90:10				
SARIMA $(0,1,1)\ (0,1,0)^{12}$	SARIMA $(1,1,2)\ (0,1,0)^{12}$	SARIMA $(2,1,3)\ (0,1,0)^{12}$	SARIMA $(4,1,0)\ (0,1,0)^{12}$	SARIMA $(5,1,1)\ (0,1,0)^{12}$
SARIMA $(0,1,2)\ (0,1,0)^{12}$	SARIMA $(1,1,3)\ (0,1,0)^{12}$	SARIMA $(3,1,0)\ (0,1,0)^{12}$	SARIMA $(4,1,1)\ (0,1,0)^{12}$	SARIMA $(5,1,2)\ (0,1,0)^{12}$
SARIMA $(0,1,3)\ (0,1,0)^{12}$	SARIMA $(2,1,0)\ (0,1,0)^{12}$	SARIMA $(3,1,1)\ (0,1,0)^{12}$	SARIMA $(4,1,2)\ (0,1,0)^{12}$	SARIMA $(5,1,3)\ (0,1,0)^{12}$
SARIMA $(1,1,0)\ (0,1,0)^{12}$	SARIMA $(2,1,1)\ (0,1,0)^{12}$	SARIMA $(3,1,3)\ (0,1,0)^{12}$	SARIMA $(4,1,3)\ (0,1,0)^{12}$	
SARIMA $(1,1,1)\ (0,1,0)^{12}$	SARIMA $(2,1,2)\ (0,1,0)^{12}$	SARIMA $(3,1,3)\ (0,1,0)^{12}$	SARIMA $(5,1,0)\ (0,1,0)^{12}$	

Sebanyak 23 model kandidat pada Tabel 1 diestimasi dan diuji signifikansi parameternya dengan metode MLE. Dari hasil tersebut, diperoleh dua model dengan seluruh parameter signifikan, yakni SARIMA $(0,1,2)\ (0,1,0)^{12}$ dan SARIMA $(1,1,1)\ (0,1,0)^{12}$. Kedua model ini lalu diuji lebih lanjut lewat uji diagnostik, mencakup independensi *error* dan normalitas *error*. Hasilnya, hanya SARIMA $(0,1,2)\ (0,1,0)^{12}$ yang memenuhi kedua asumsi

tersebut. Atas dasar itu, model SARIMA $(0,1,2)\ (0,1,0)^{12}$ ditetapkan sebagai model yang digunakan untuk peramalan. Persamaan model dinyatakan pada persamaan (16) sebagai berikut, dengan koefisien MA memakai konvensi $\Theta(B) = 1 - \theta_1 B - \theta_2 B^2$:

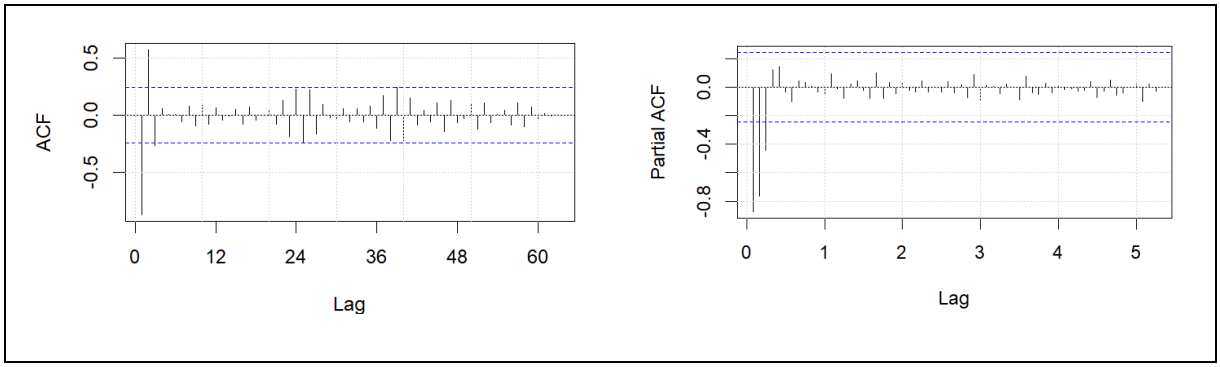
$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} - \theta_1 a_{t-1} - \theta_2 a_{t-2} + a_t \qquad (16)$$

Berdasarkan Persamaan 15, dihitung hasil peramalan jumlah produksi kopi Indonesia untuk periode Januari hingga Desember 2026 sebagaimana pada Tabel 2.

Tabel 2. Peramalan Jumlah Produksi Kopi di Indonesia Periode Januari-Desember 2026

Periode	Bulan	Hasil Peramalan (Ribu Ton)	Periode	Bulan	Hasil Peramalan (Ribu Ton)
97	Januari 2026	0,01	103	Juli 2026	0,62
98	Februari 2026	0,01	104	Agustus 2026	0,55
99	Maret 2026	0,01	105	September 2026	0,19
100	April 2026	0,02	106	Oktober 2026	0,06
101	Mei 2026	0,24	107	November 2026	0,03
102	Juni 2026	0,56	108	Desember 2026	0,01

Tahapan analisis proporsi 80:20 pada dasarnya sama seperti proporsi 90:10. Pengujian stasioneritas melalui tranformasi Box-Cox menghasilkan nilai λ=0,99998, yang mengindikasikan data telah stasioner dalam varians, namun belum stasioner dalam rata-rata karena masih menunjukan pola musiman (Gambar 1). Oleh karena itu, dilakukan *differencing* nonmusiman (*d=1*) dan *differencing* musiman orde 12 (*D=1*), karena pola musiman di *lag* 12, 24, dan 36 masih belum stasioner. Setelah *differencing,* data telah stasioner sepenuhnya, ditunjukkan oleh pola *cut off* pada Gambar 3.



Gambar 3. Grafik ACF dan PACF data jumlah produksi kopi di Indonesia periode Januari 2018 hingga Mei 2024.

Tabel 3. Model SARIMA Sementara Proporsi 80:20

Model Sementara SARIMA 80:20				
SARIMA $(0,1,1)\ (0,1,0)^{12}$	SARIMA $(1,1,0)\ (0,1,0)^{12}$	SARIMA $(1,1,3)\ (0,1,0)^{12}$	SARIMA $(2,1,2)\ (0,1,0)^{12}$	SARIMA $(3,1,1)\ (0,1,0)^{12}$
SARIMA $(0,1,2)\ (0,1,0)^{12}$	SARIMA $(1,1,1)\ (0,1,0)^{12}$	SARIMA $(2,1,0)\ (0,1,0)^{12}$	SARIMA $(2,1,3)\ (0,1,0)^{12}$	SARIMA $(3,1,2)\ (0,1,0)^{12}$
SARIMA $(0,1,3)\ (0,1,0)^{12}$	SARIMA $(1,1,2)\ (0,1,0)^{12}$	SARIMA $(2,1,1)\ (0,1,0)^{12}$	SARIMA $(3,1,0)\ (0,1,0)^{12}$	SARIMA $(3,1,3)\ (0,1,0)^{12}$

Berdasarkan Gambar 3, grafik ACF menunjukkan nilai signifikan hingga *lag* 1–3 sebelum *cut off*, mengindikasikan orde MA nonmusiman (q=3) dengan komponen musiman tidak signifikan (Q=0). Pola serupa terlihat pada grafik PACF, dengan *lag* 1–3 signifikan yang menunjukkan orde AR nonmusiman (p=3) dan komponen musiman tidak signifikan (P=0).

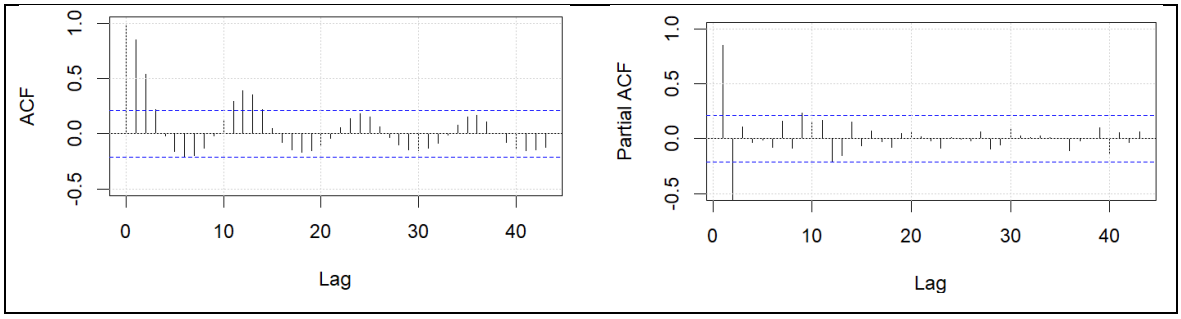
Kombinasi orde ini menghasilkan 15 model SARIMA sementara yang dapat dilihat pada Tabel 3

Seluruh kandidat model pada Tabel 3 diestimasi dan diuji signifikansi parameternya dengan metode MLE. Dari 15 model, hanya model SARIMA $(0,1,2)\ (0,1,0)^{12}$ dan SARIMA $(1,1,1)\ (0,1,0)^{12}$ yang seluruh parameternya signifikan. Setelah diuji diagnostik, hanya model SARIMA $(0,1,2)\ (0,1,0)^{12}$ yang asumsi independensi dan normalitas *error*, sementara SARIMA $(1,1,1)\ (0,1,0)^{12}$ gagal pada uji normalitas. Model SARIMA $(0,1,2)\ (0,1,0)^{12}$ dipilih untuk peramalan, dengan menggunakan Persamaan 15 hasil peramalan jumlah produksi kopi Indonesia periode Januari-Desember 2026 untuk proporsi 80:20 disajikan pada Tabel 4.

Tabel 4. Peramalan Jumlah Produksi Kopi di Indonesia Periode Januari-Desember 2026

Periode	Bulan	Hasil Peramalan (Ribu Ton)	Periode	Bulan	Hasil Peramalan (Ribu Ton)
97	Januari 2026	0,01	103	Juli 2026	1,00
98	Februari 2026	0,01	104	Agustus 2026	0,84
99	Maret 2026	0,01	105	September 2026	0,27
100	April 2026	0,01	106	Oktober 2026	0,07
101	Mei 2026	0,41	107	November 2026	0,01
102	Juni 2026	0,93	108	Desember 2026	0,01

Pada tahap awal pemodelan ANN, variabel input ditentukan berdasarkan *lag* signifikan yang teridentifikasi melalui grafik ACF dan PACF data jumlah produksi kopi Indonesia. Pemilihan *lag* signifikan ini bertujuan agar variabel *input* yang digunakan memiliki korelasi yang kuat terhadap pola data. Hasil grafik ACF dan PACF ditampilkan pada Gambar 4.



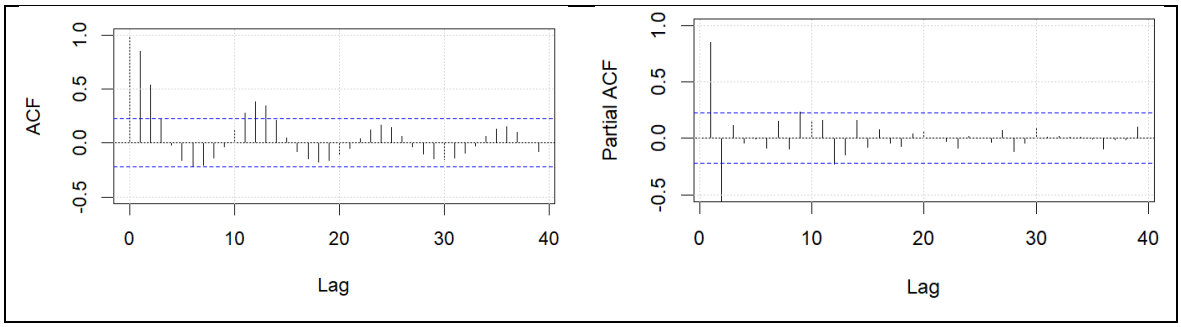
Gambar 4. Grafik ACF dan PACF data jumlah produksi kopi di Indonesia.

Berdasarkan Gambar 4, grafik ACF memiliki 8 *lag* signifikan (*lag* ke-1, 2, 3, 6, 11, 12, 13, dan 14) lebih banyak dibanding PACF yang hanya 4 *lag* signifikan (*lag* ke-1, 2, 9, dan 12), sehingga *lag* pada ACF dijadikan dasar penentuan variabel *input*. Arsitektur ANN yang digunakan adalah MLP dengan algoritma *backpropagation*, dengan jumlah *neuron hidden layer* dicoba dari 1 hingga 5, *learning rate* 0,001, fungsi aktivasi sigmoid biner pada *hidden layer* dan linier pada *output layer*. Proses pembelajaran dihentikan pada target *error* 0,001 atau maksimum 10.000.000 iterasi. Hasil pemodelan menunjukan bahwa arsitektur dengan 4 *neuron* pada *hidden layer* menghasilkan nilai *error* terkecil dan merupakan model terbaik dengan proporsi ini, dengan proses pembelajaran berhenti pada iterasi ke-1.827.901 setelah mencapai nilai *error* sebesar 0,01837. Berdasarkan model terpilih, dilakukan peramalan jumlah produksi kopi Indonesia untuk periode Januari hingga Desember 2026. Hasil peramalan tersebut disajikan pada Tabel 5 berikut:

Tabel 5. Peramalan Jumlah Produksi Kopi di Indonesia Model ANN Arsitektur 4 *Neuron* Proporsi 90:10

Periode	Bulan	Hasil Peramalan (Ribu Ton)	Periode	Bulan	Hasil Peramalan (Ribu Ton)
97	Januari 2026	0,03	103	Juli 2026	0,55
98	Februari 2026	0,09	104	Agustus 2026	0,38
99	Maret 2026	0,25	105	September 2026	0,22
100	April 2026	0,43	106	Oktober 2026	0,19
101	Mei 2026	0,62	107	November 2026	0,14
102	Juni 2026	0,68	108	Desember 2026	0,10

Sama seperti tahap sebelumya yaitu proporsi 90:10, penentuan variabel *input* dengan proporsi 80:20 ini juga mengacu pada *lag* signifikan dari grafik ACF dan PACF data jumlah produksi kopi di Indonesia, agar variabel yang dipilih benar-benar berkorelasi kuat terhadap pola datanya. Grafik ACF dan PACF proporsi ini dapat dilihat pada Gambar 5.



Gambar 5. Grafik ACF dan PACF data jumlah produksi kopi di Indonesia.

Gambar 5 terlihat ACF memiliki 6 *lag* signifikan (*lag* ke-1, 2, 6, 11, 12, dan 13) yang jumlahnya lebih banyak dibanding PACF yang hanya 4 *lag* signifikan (*lag* ke-1, 2, 9, dan 12). Sehingga *lag* signifikan pada ACF ini dipakai sebagai acuan penentuan variabel *input*. Arsitektur ANN yang digunakan tetap sama seperti proporsi sebelumnya, yaitu MLP dengan algoritma *backpropagation*, jumlah *neuron* pada *hidden layer* dicoba dari 1 hingga 5, dengan target *error* 0,001 atau maksimum 10.000.000 iterasi. Setelah model dijalankan, model dengan 5 *neuron* pada *hidden layer* memberikan nilai *error* terkecil dan merupakan model terbaik dengan proporsi 80:20, dengan proses pembelajaran berhenti pada iterasi ke-1.367.684 setelah mencapai nilai *error* sebesar 0,01525. Berdasarkan model terpilih, dilakukan peramalan jumlah produksi kopi Indonesia untuk periode Januari hingga Desember 2026, yang disajikan pada Tabel 5 berikut:

Tabel 6. Peramalan Jumlah Produksi Kopi di Indonesia Model ANN Arsitektur 5 *Neuron* Proporsi 80:20

Periode	Bulan	Hasil Peramalan (Ribu Ton)	Periode	Bulan	Hasil Peramalan (Ribu Ton)
97	Januari 2026	0,01	103	Juli 2026	0,79
98	Februari 2026	0,02	104	Agustus 2026	0,54
99	Maret 2026	0,06	105	September 2026	0,27
100	April 2026	0,22	106	Oktober 2026	0,10
101	Mei 2026	0,50	107	November 2026	0,03
102	Juni 2026	0,73	108	Desember 2026	0,01

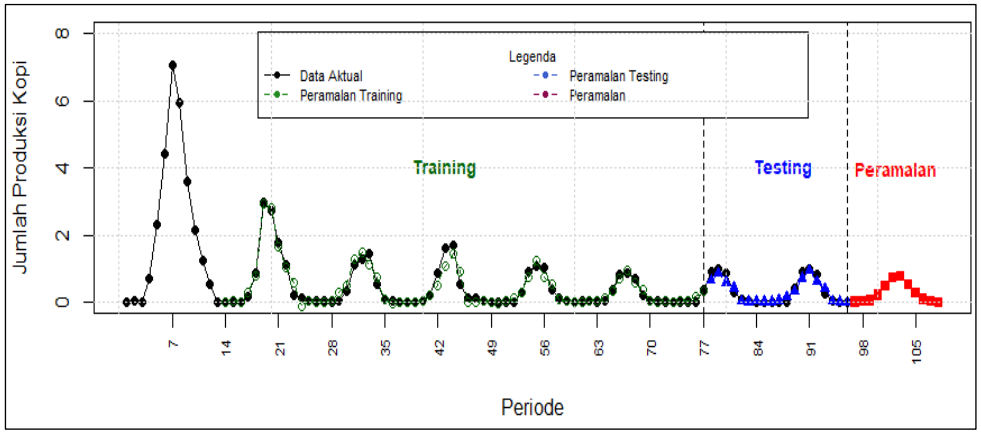
Setelah dilakukan analisis terhadap model SARIMA dan ANN pada masing-masing skema proporsi data, selanjutnya dilakukan perbandingan kinerja kedua model tersebut berdasarkan nilai evaluasi *error,* sebagaimana disajikan pada Tabel 7. Model SARIMA

$(0,1,2)(0,1,0)^{12}$ dengan proporsi 90:10 menghasilkan *error* lebih kecil dan stabil dibandingkan proporsi 80:20, sehingga ditetapkan sebagai skema terbaik untuk SARIMA. Sebaliknya, pada ANN, arsitektur 5 *neuron* dengan proporsi 80:20 unggul pada fase *training* dan gabungan, dibandingkan arsitektur 4 *neuron* dengan proporsi 90:10, meskipun pada fase *testing* RMSE proporsi 90:10 sedikit lebih baik. Pada proporsi 80:20, ANN 5 *neuron* memiliki RMSE dan MAE *testing* lebih kecil daripada SARIMA (0,13366; 0,18936 dan 0,09750; 0,12552), tetapi MASE *testing*-nya lebih besar (0,37182; 0,31104). Pada proporsi 90:10, SARIMA lebih baik daripada ANN 4 *neuron* pada ketiga metrik *testing*. Dengan demikian, keunggulan ANN tidak konsisten pada seluruh metrik dan skema, dan periode *testing* kedua proporsi berbeda (10 dan 19 bulan). ANN 5 *neuron* 80:20 dipilih sebagai model peramalan berdasarkan RMSE dan MAE *testing* pada skema 80:20 yang periode *testing*-nya lebih panjang.

Tabel 7. Perbandingan Nilai Evaluasi *Error* Model SARIMA dan ANN

Model	Proporsi	Data	RMSE	MAE	MASE
SARIMA $(0,1,2)(0,1,0)^{12}$	90:10	*Training*	0,32305	0,14472	0,38119
		Testing	0,11561	0,07960	0,20967
		Gabungan	0,30803	0,13793	0,36332
SARIMA $(0,1,2)(0,1,0)^{12}$	80:20	*Training*	0,34255	0,15337	0,38006
		Testing	0,18936	0,12552	0,31104
		Gabungan	0,31814	0,14786	0,36640
ANN 4 *Neuron*	90:10	*Training*	0,15902	0,11807	0,46264
		Testing	0,12249	0,10514	0,41198
		Gabungan	0,15503	0,11649	0,45646
ANN 5 *Neuron*	80:20	*Training*	0,15368	0,10303	0,39291
		Testing	0,13366	0,09750	0,37182
		Gabungan	0,15138	0,10235	0,39034

Berdasarkan hasil perbandingan pada Tabel 7, model ANN berarsitektur 5 *neuron* dengan proporsi data 80:20 ditetapkan sebagai model terbaik dan digunakan untuk meramalkan jumlah produksi kopi Indonesia periode Januari–Desember 2026, dengan hasil peramalan yang tercantum pada Tabel 6. Berdasarkan tabel tersebut, nilai produksi kopi diprediksi berada pada rentang 0,01 hingga 0,79 ribu ton, dengan titik tertinggi terjadi pada Juli 2026 (0,79 ribu ton), sementara nilai terendah muncul pada Januari dan Desember 2026, yaitu masing-masing sebesar 0,01 ribu ton. Secara visual, hasil peramalan tersebut tersaji pada Gambar 6 berikut.



Gambar 6. Grafik perbandingan data aktual dengan hasil peramalan jumlah produksi kopi di Indonesia Model Terbaik ANN arsitektur *5 neuron*

Gambar 6, menunjukkan bahwa peramalan ANN 5 *neuron* mengikuti pola musiman data historis, yaitu produksi naik pada awal tahun, mencapai puncak pada Juni–Juli, lalu turun menjelang akhir tahun. Pada data *testing,* model menghasilkan RMSE 0,13366, MAE 0,09750, dan MASE 0,37182 ribu ton. Nilai MASE di bawah 1 menunjukkan bahwa model lebih baik daripada peramalan naif. Peramalan 2026 memperkirakan puncak produksi pada Juli sebesar 0,79 ribu ton dan nilai terendah sebesar 0,01 ribu ton pada Januari dan Desember. Hasil ini dapat menjadi gambaran awal pasokan kopi dari sisi produksi nasional, sehingga berguna untuk perencanaan pengadaan bahan baku, kapasitas pengolahan, dan distribusi.

5. KESIMPULAN

Model SARIMA $(0,1,2)$ $(0,1,0)^{12}$ dengan proporsi 90:10 meramalkan jumlah produksi kopi di Indonesia periode Januari–Desember 2026 dengan pola naik dari 0,01 ke 0,62 ribu ton (Januari–Juli), lalu turun menjadi 0,01 ribu ton (Agustus–Desember), dengan nilai gabungan RMSE 0,30803, MAE 0,13793, dan MASE 0,36332. Sementara itu, Model ANN 5 *neuron* dengan proporsi 80:20 meramalkan pola serupa, naik dari 0,01 ke 0,79 ribu ton (Januari–Juli), lalu turun menjadi 0,01 ribu ton (Agustus–Desember), dengan nilai gabungan RMSE 0,15138, MAE 0,10235, dan MASE 0,39034. Perbandingan kedua model menunjukan bahwa Model ANN 5 *neuron* dengan proporsi 80:20 merupakan model terbaik untuk meramalkan produksi kopi Indonesia, dengan nilai *error* yang lebih rendah dibandingkan SARIMA. Berdasarkan hasil tersebut, penelitian selanjutnya disarankan untuk mengembangkan model peramalan lain, seperti *Singular Spectrum Analysis* (SSA) untuk menangani komponen tren dan musiman, atau *Long Short-Term Memory* (LSTM) sebagai alternatif dari model ANN. Selain itu, penelitian selanjutnya juga dapat menerapkan pendekatan model *ensemble* dengan menggabungkan nilai prediksi dari model SARIMA dan ANN.

DAFTAR PUSTAKA

Anggraini, D. A., Wahyuningsih, S., & Siringoringo, M. (2023). Peramalan Harga Minyak Mentah Indonesia Jenis Sepinggan Yakni Mix Menggunakan Model *Hybrid Autoregressive Integrated Moving Averagr-Neural Network. Riset Pembangunan, 5(2)* 105-118. https://doi.org/10.36087/jrp.v5i2.138.

Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time Series Analysis: Forecasting and Control* (Fifth). John Wiley & Sons, Inc.

Guntara, M., Santi, I. G. A. D. G. K., & Priyanto, D. (2025). Pendekatan Aritificial Neural Network untuk Prediksi Hasil Panen Kopi dengan Metode Backpropagation. *Seminar Nasional Corisindo*, *1*(1), 258–264. https://journal.universitasbumigora.ac.id/corisindo2025/article/view/5362.

Hermawan, K. D. K., Cahyarani, A. I., Siregar, T. K. H., & Kartiasih, F. (2025). Peramalan Produksi Gula Tebu di Indonesia Menggunakan Model Hybrid SARIMA (SARIMA-ANN) dalam Mengukur Capaian Swasembada Gula 2025. *Agricore: Jurnal Agribisnis Dan Sosial Ekonomi Pertanian Unpad*, *10*(1), 132–149. https://doi.org/10.24198/agricore.v10i1.62470.

Ichwan, M., & Alfarisyi, S. F. (2024). Pemodelan Ritme Kalori Terbakar Setiap Waktu Selama Bersepeda dengan Feedforward Neural Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, *12*(1), 13–22. https://doi.org/10.26760/elkomika.v12i1.13.

Julianti, A. R., Ruhiat, D., & Rahayu, S. D. (2024). Komparasi Forecasting Tingkat Inflasi di Indonesia Menggunakan Metode Artificial Neural Network Backpropagation dan Metode Seasonal ARIMA. *Jurnal Riset Matematika Dan Sains Terapan*, *4*(1), 14–22. https://ejournal.unibba.ac.id/index.php/jrmst/article/view/1504.

Juliarto, H. K., Purnamasari, I., & Prangga, S. (2023). Peramalan Peredaran Uang Kartal di Indonesia Menggunakan Model *Hybrid* SARIMAX-*Neural Network. GAUSSIAN, 12(4),* 465-476. https://doi.org/10.14710/j.gauss.12.4.465-476.

Kuntarini, A. A. W. (2024). Pendekatan Neural Network dalam Peramalan Jumlah Penduduk Kota Semarang dengan Menggunakan Metode Backpropagation. *ESTIMASI: Journal of Statistics and Its Application*, *5*(2), 230–239. https://doi.org/10.20956/ejsa.v5i2.28112.

Nasirudin, F., Pindianti, M., Said, D. I. S., & Widodo, E. (2022). Permalan Jumlah Produksi Kopi Di Jawa Timur Pada Tahun 2020-2021 Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA). *Agrium*, *25*(1), 34–43. https://doi.org/10.30596/agrium.v25i1.8211.

Ngestisari, W., Susanto, B., & Mahatma, T. (2020). Perbandingan Metode ARIMA dan Jaringan Syaraf Tiruan untuk Peramalan Harga Beras. *Indonesian Journal of Data and Science (IJODAS)*, *1*(3), 96–107. https://doi.org/10.33096/ijodas.v1i3.18.

Panggabean, E., & Sagala, J. R. (2021). Analisa Perbandingan Metode Jaringan Syaraf Tiruan Dengan Metode Sistem Pendukung Keputusan Untuk Penerimaan Tenaga Kerja. *MEDIA INFORMATIKA (JUMIN)*, *2*(2), 74–80. https://doi.org/10.55338/jumin.v2i2.697.

Paryanto, E. (2025). Permintaan Kopi Indonesia: Faktor Penentu Dan Implikasinya Terhadap Industri Kopi. *Journal of Economy, Business, Entrepreneuship and Finance*, *5*(1), 145–155. https://doi.org/10.53067/ijebef.

Hendayanti, Putu, N., Nurhidayati, M., & Artikel, R. (2020). Perbandingan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA) dengan Support Vector Regression (SVR) dalam Memprediksi Jumlah Kunjungan Wisatawan Mancanegara ke Bali INFO ARTIKEL ABSTRAK. *Jurnal Varian*, *3*(2), 149–162. https://doi.org/10.30812/varian.v3i1

Sitorus, A. R., Manurung, S., & Purba, M. J. (2025) Peramalan Jumlah Ikan Air Tawar di Kota Tebing Tinggi dengan Metode SARIMA. *Jurnal Ilmiah Sistem Informasi, 5(2),* 1-9. https://ejurnal.methodist.ac.id/index.php/methosisfo/article/view/4833.

Syuhada, E. G., & Setyawan, M. Y. H. (2023). Analisis Komparasi Metode Prophet Dan Metode Exponential Smoothing Dalam Peramalan Jumlah Pengangguran Di Jawa Barat: Systematic Literature Review. *Jurnal Mahasiswa Teknik Informatika*, *7*(2), 1369–1377. https://doi.org/10.36040/jati.v7i2.6827.

Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate*.