Jurnal Gaussian_lanjutan

By Plagiarism Check

WORD COUNT 5054
TIME SUBMITTED 04-AUG-2026 03:23AM
PAPER ID 123406709

ISSN: 2339-2541
JURNAL GAUSSIAN, Volume X, Nomor X, Tahun XXXX, Halaman XX - XX
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[2*], Desi Yuniarti[3], Meiliyani Siringoringo[4], M. Fathurahman[5]
[1,2,3] Program Studi Statistika, Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Mulawarman
***e-mail**: swahyuningsih@gmail.ac.id

DOI: 10.14710/J.GAUSS.XX.X.XX-XX

Article Info:
Received:
Accepted:
Available Online:

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 neuron architecture, was obtained at the 80:20 proportion with an RMSE of 0.15138, MAE of 0.10235, and MSE 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

Suatu model yang memanfaatkan pola data historis untuk memprediksi nilai di masa depan disebut sebagai peramalan. Salah satu model yang umum digunakan adalah *Seasonal Autoregressive Integrated Moving Average* (SARIMA), yang unggul menangkap pola linier dan musiman, namun kurang mampu menangkap informasi nonlinier pada data (Hermawan, Cahyarani, Siregar, & Kartiasih, 2025). Untuk mengatasi kekurangan tersebut, dikembangkan pendekatan *Artificial Neural Network* (ANN), yang mampu menangkap hubungan nonlinier tanpa memerlukan asumsi stasioneritas (Panggabean & Sagala, 2021). Perbandingan langsung SARIMA dan ANN telah dilakukan pada berbagai bidang ekonomi, seperti harga beras (Ngestisari, Susanto, & Mahatma, 2020) dan inflansi (Julianti, Ruhiat, & Rahayu, 2024). Hasil-hasil tersebut secara konsisten menunjukkan bahwa tidak ada satu model yang unggul di seluruh studi kasus, karena performa keduanya bergantung pada karakteristik data yang dianalisis. Berdasarkan hal tersebut, perbandingan SARIMA dan ANN perlu dilakukan kembali pada tiap domain data baru, alih-alih mengasumsikan satu model unggul secara umum.

Salah satu domain dengan pendekatan ini adalah sektor perkebunan kopi. Sebagai negara penghasil kopi terbanyak keempat di dunia, tingkat konsumsi kopi di dalam negeri Indonesia tumbuh rata-rata 13,9% per tahun, jauh melampaui pertumbuhan konsumsi global (Paryanto, 2025). Namun, tingginya permintaan ini berbanding terbalik dengan pola produksinya yang musiman, dengan puncak panen pada Agustus-September, sekaligus diwarnai fluktuasi yang tidak sepenuhnya beraturan (Nasirudin, Pindianti, Said, & Widodo, 2022). Karakteristik ganda ini menjadikan data produksi kopi objek yang tepat untuk diuji dengan kedua pendekatan tersebut, mengingat penelitian terdahulu masih menggunakan satu

pendekatan secara terpisah pada lingkup provinsi tertentu, baik ANN (Guntara, Santi, & Priyanto, 2025) maupun SARIMA (Nasirudin, Pindianti, Said, & Widodo, 2022), tanpa perbandingan kedua model di tingkat nasional.

Penelitian ini bertujuan untuk mengkaji perbandingan performa antara model SARIMA dan ANN dalam meramalkan jumlah produksi kopi Indonesia periode Januari 2018–Desember 2025 menggunakan indikator RMSE, MAE, dan MASE, serta menghasilkan nilai peramalan produksi kopi Indonesia untuk 12 bulan ke depan, yakni Januari hingga Desember 2026.

2. TINJAUAN PUSTAKA

2.1. Periodogram

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 (ω_m) dan koefisien Fourier (A_m) dan (E_m) yang diperoleh dari persamaan sebagai berikut:

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

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

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

Menghitung nilai periodogram menggunakan persamaan berikut:

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

Untuk menentukan periode musiman dapat menggunakan persamaan berikut:

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

2.2. *Seasonal Autoregressive Integrated Moving Average*

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 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*

d : Orde *differencing*

D : Orde *differencing* musiman

s : Jumlah periode musiman

a_t : *Error* pada waktu ke-t yang diasumsikan mengikuti proses *white noise*.

2.3. *Artificial Neural Network*

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 laryer,* dan *output* (Kuntarini, 2024). Berdasarkan jumlah *hidden layer*-nya, ANN dibedakan menjadi *single layer perceptron* (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 sebagai berikut:

$$f_1(x) = \frac{1}{1+e^{-x}} \text{ untuk } -\infty < x < \infty \text{ dengan } f_1'(x) = f_1(x)[1-f_1(x)] \quad (6)$$

- 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 dinyatakan sebagai berikut:

$$f_3(x) = x \text{ untuk } -\infty < x < \infty \text{ dengan } f_3'(x) = 1 \quad (7)$$

2.4. Evaluasi *Error* Peramalan

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):

$$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n}(Y_t - F_t)^2} \quad (8)$$

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):

$$MAE = \frac{\sum_{i=1}^{n}|Y_t - F_t|}{n} \quad (9)$$

MASE sebagai alternatif MAPE, karena MAPE tidak dapat digunakan pada data bernilai nol/sangat kecil dan sensitive terhadap *outlier*.

$$MASE = \frac{\frac{1}{n}\sum_{t-1}^{n}|a_t|}{\frac{1}{n-1}\sum_{t-2}^{n}|Y_t - Y_{t-1}|} \quad (10)$$

Dengan Y_t: nilai aktual, F_t: nilai prediksi, a_t: *error* pada periode ke-t dan n: banyaknya data pengamatan.

3. METODE PENELITIAN

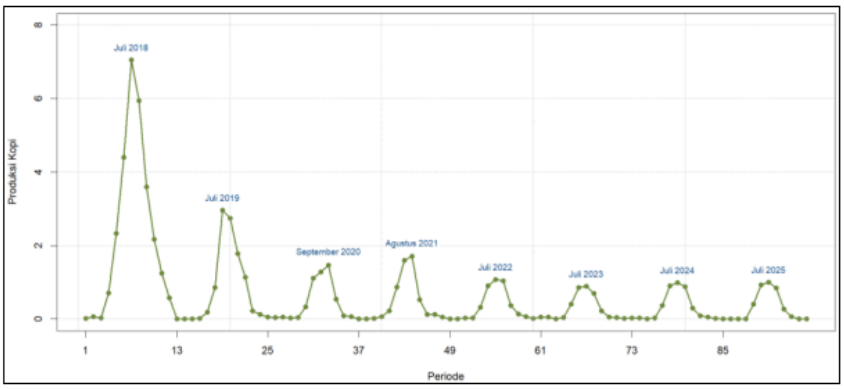
Data yang digunakan dalam penelitian ini merupakan data sekunder, yaitu data jumlah produksi kopi di Indonesia yang diperoleh dari situs resmi Badan Pusat Statistik (BPS) (https://www.bps.go.id/). Populasi dalam penelitian ini adalah jumlah produksi kopi di Indonesia, dengan sampel berupa data jumlah produksi kopi di Indonesia periode Januari 2018 sampai Desember 2025. Teknik pengambilan sampel yang digunakan adalah *purposive sampling*. Variabel yang digunakan dalam penelitian ini adalah jumlah produksi kopi di Indonesia dengan satuan ribu ton, dengan metode analisis yang digunakan yaitu 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 peramalan model ANN data jumlah produksi kopi di Indonesia pada masing-masing proporsi.
8. Membandingkan hasil evaluasi *error* permalan dari model terbaik masing-masing model untuk menentukan model dengan performa terbaik.

4. HASIL DAN PEMBAHASAN

4.1. Deskripsi Data

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.

Berdasarkan Gambar 1, terlihat pola musiman yang berulang setiap tahun, dengan puncak produksi tertinggi terjadi pada juli 2018, dan titik terendah pada awal tahun (Januari-Maret). Pola ini konsisten berulang pada tahun-tahun berikutnya, mengindikasikan adanya musiman dalam data.

Data selanjutnya dibagi menjadi data *training* dan *testing* dengan dua skema proporsi, yaitu 90:10 dan 80:20, untuk menguji konsistensi model dalam mengenali pola musiman dan tren produksi. Pada proporsi 90:10, data *training* mencakup 86 periode (Januari 2018-Februari 2025) dan data *testing* 10 periode (Maret–Desember 2025). Pada proporsi 80:20, data *training* mencakup 77 periode (Januari 2018–Mei 2024) dan data *testing* 19 periode (Juni–Desember 2025).

4.2. Analisis Periodogram

4.2.1. Analisis periodogram proporsi 90:10

Periodogram digunakan untuk mengecek pola musiman pada data jumlah produksi kopi di Indonesia. Hasil analisis menunjukkan bahwa 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:

$$T^* = \frac{2\pi}{\omega_7} = \frac{2\times 3,14159}{0,51142} = 12,28575 \approx 12 \qquad (11)$$

Dari hasil perhitungan tersebut, dapat diketahui bahwa pada proporsi 90:10, pola musiman data jumlah produksi kopi di Indonesia berulang setiap 12 periode atau setara dengan 12 bulan.

4.2.2. Analisis periodogram proporsi 80:20

Analisis periodogram 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:

$$T^* = \frac{2\pi}{\omega_7} = \frac{2\times 3,14159}{0,48960} = 12,83333 \approx 12 \qquad (12)$$

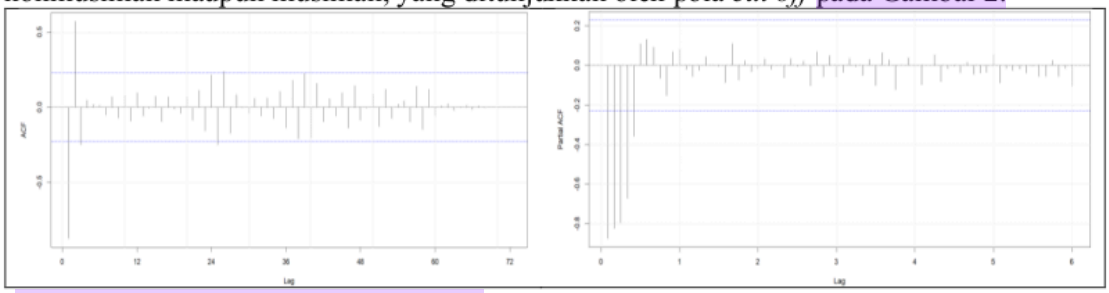
Hasil perhitungan menunjukkan bahwa jumlah produksi kopi di Indonesia pada proporsi 80:20 memiliki pola musiman selama 12 bulan.

4.3. Pemodelan SARIMA

4.3.1.Analisis Model SARIMA Proporsi 90:10

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 sebagai berikut:

Tabel 1. Model SARIMA Sementara Proporsi 90:10

Model Sementara SARIMA				
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 *maximum likelihood estimator* (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 level uji diagnostik, mencakup independensi *error* dan normalitas *error*. Hasilnya, hanya SARIMA $(0,1,2)\ (0,1,0)^{12}$ yang memenuhi kedua asumsi tersebut, sedangkan SARIMA $(1,1,1)\ (0,1,0)^{12}$ gagal pada uji normalitas *error*. Atas dasar itu, model SARIMA $(0,1,2)\ (0,1,0)^{12}$ ditetapkan sebagai model yang digunakan untuk peramalan. Persamaan model dinyatakan sebagai berikut:

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

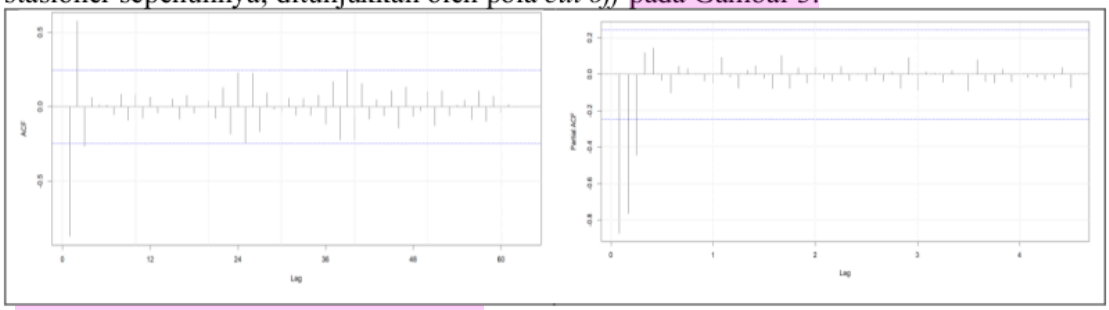
dengan nilai evaluasi *error*, dimana nilai RMSE, MASE, dan MSE berturut-turut sebesar 0,32305; 0,14472; dan 0,38119 pada data *training*, sebesar 0,11561; 0,07960; dan 0,20967 pada data *testing*, serta sebesar 0,30803; 0,13793; dan 0,36332 pada data gabungan. Berdasarkan Persamaan (13), dihitung hasil 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

4.3.2.Analisis Model SARIMA Proporsi 80:20

Tahapan analisis pada proporsi ini pada dasarnya sama seperti proporsi sebelumnya. 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.

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 berikut:

Tabel 3. Model SARIMA Sementara Proporsi 80:20

Model Sementara SARIMA				
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 $(3,1,3)\ (0,1,0)^{12}$

Seluruh kandidat model pada Tabel 4 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 nilai dengan nilai RMSE, MAE, dan MASE masing-masing

sebesar 0,34255; 0,15337; dan 0,38006 pada data *training*, sebesar 0,18936; 0,12552; dan 0,31104 pada data *testing*, serta sebesar 0,31814; 0,14786; dan 0,36640 pada data gabungan. Hasil peramalan jumlah produksi kopi Indonesia periode Januari-Desember 2026 menggunakan Persamaan 13 disajikan pada Tabel 4.

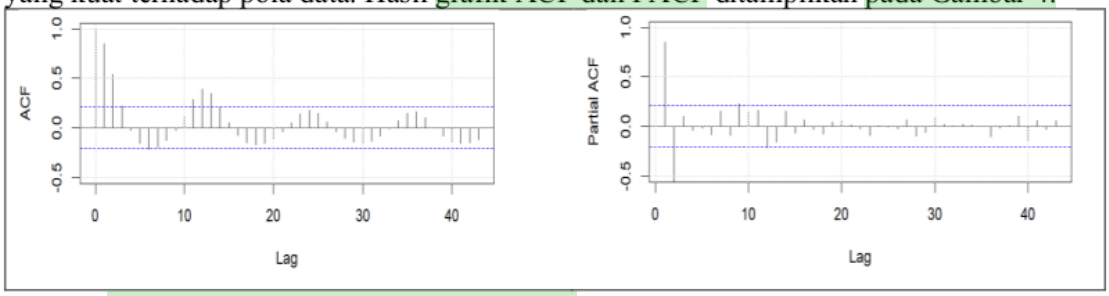
Tabel 4. Peramalan Jumlah Produksi Kopi di Indonesia Periode Januari-Desember 2026

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

4.4. Pemodelan ANN

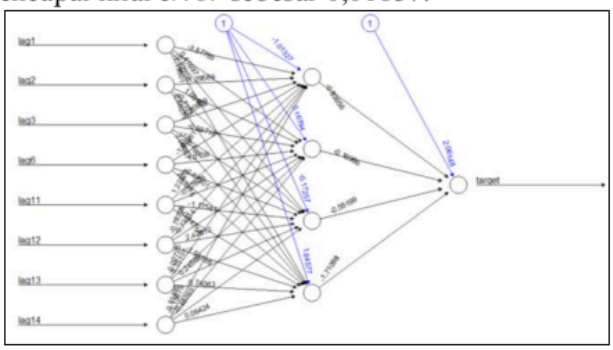
4.4.1.Analisis Model ANN Proporsi 90:10

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* (Gambar 5) menghasilkan nilai *error* terkecil dan merupakan model terbaik dalam proporsi ini, dengan proses pembelajaran berhenti pada iterasi ke-1.827.901 setelah mencapai nilai *error* sebesar 0,01837.



Gambar 5. Arsitektur jaringan *backpropagation* dengan 4 *neuron*

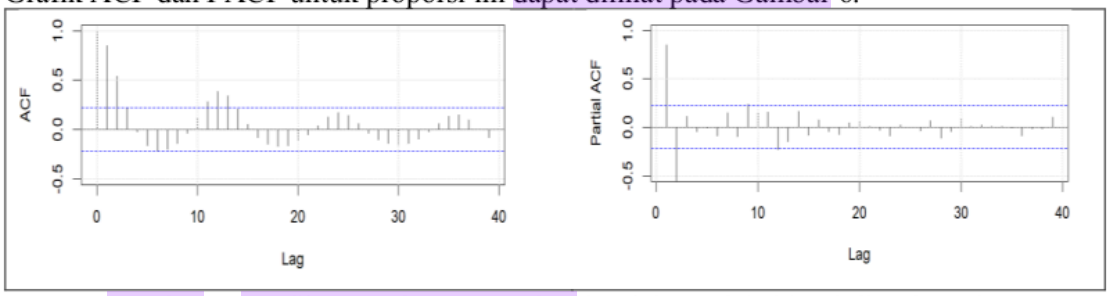
Model ANN dengan 4 *neuron* pada *hidden layer* menghasilkan nilai RMSE, MAE, dan MASE berturut-turut sebesar 0,15902; 0,11807; dan 0,46264 pada data *training*, sebesar 0,12249; 0,10514; dan 0,41198 pada data *testing*, serta sebesar 0,15503; 0,11649; dan 0,45646 pada data gabungan. Berdasarkan model terpilih, dilakukan peramalan jumlah produksi kopi Indonesia untuk periode Januari hingga Desember 2026, dengan hasil berikut:

Tabel 5. Peramalan Jumlah Produksi Kopi di Indonesia Model ANN Arsitektur 4 *Neuron*

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

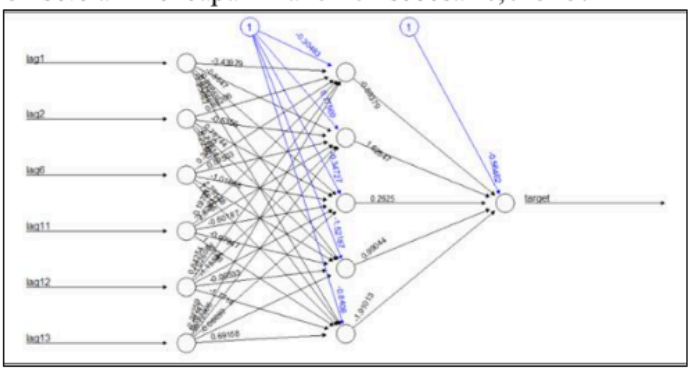
4.4.2.Analisis Model ANN Proporsi 80:20

Sama seperti tahap sebelumya, penentuan variabel *input* pada 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 untuk proporsi ini dapat dilihat pada Gambar 6.



Gambar 6. Grafik ACF dan PACF data jumlah produksi kopi di Indonesia.

Dari Gambar 6 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* (Gambar 7) memberikan nilai *error* terkecil dan merupakan model terbaik dalam proporsi 80:20, dengan proses pembelajaran berhenti pada iterasi ke-1.367.684 setelah mencapai nilai *error* sebesar 0,01525.



Gambar 7. Arsitektur jaringan *backpropagation* dengan 5 *neuron*

Model ANN dengan 5 *neuron* pada *hidden layer* menghasilkan nilai RMSE, MAE, dan MASE berturut-turut sebesar 0,15368; 0,10288; dan 0,39291 pada data *training*, sebesar 0,13366; 0,09750; dan 0,37182 pada data *testing*, serta sebesar 0,14933; 0,10165; dan 0,39034 pada data gabungan. Berdasarkan model terpilih, dilakukan peramalan jumlah produksi kopi Indonesia untuk periode Januari hingga Desember 2026, dengan hasil berikut:

Tabel 6. Peramalan Jumlah Produksi Kopi di Indonesia Model ANN Arsitektur 5 *Neuron*

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

4.5. Perbandingan Kinerja Model

Perbandingan kinerja model SARIMA dan ANN pada kedua skema proporsi data disajikan pada Tabel 7. Model SARIMA $(0,1,2)\ (0,1,0)^{12}$ pada 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* proporsi 90:10, meski proporsi 90:10 sedikit lebih baik pada RMSE fase *testing*. Pada proporsi yang sama, ANN secara umum menghasilkan nilai RMSE dan MAE yang lebih kecil dibandingkan SARIMA, menunjukkann kesalahan absolut yang lebih kecil, meskipun pada MASE gabungan SARIMA justru sedikit lebih baik. Hal ini mengindikasikan bahwa keunggulan ANN tidak mutlak di seluruh ukuran evaluasi, namun karena ANN unggul pada dua dari tiga metrik (RMSE dan MAE), ANN tetap dinilai lebih baik dibandingkan SARIMA pada proporsi yang sama. Secara keseluruhan, ANN arsitektur 5 *neuron* pada proporsi 80:20 menghasilkan nilai *error* terkecil di antara seluruh model, mengindikasikan pendekatan nonlinier ANN lebih efektif dalam menangkap pola data jumlah produksi kopi Indonesia dibandingkan pendekatan linier SARIMA, sehingga ditetapkan sebagai model terbaik untuk peramalan.

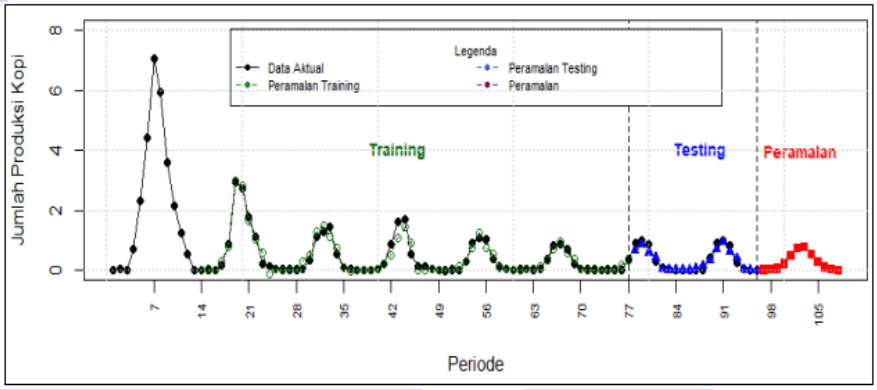
Tabel 7. Perbandingan Nilai Evaluasi *Error* Model SARIMA dan ANN

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

4.6. Hasil Peramalan Model Terbaik

Peramalan jumlah produksi kopi Indonesia periode Januari–Desember 2026 dilakukan menggunakan model ANN berarsitektur 5 neuron dengan proporsi data 80:20, dengan hasil

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 8 berikut.



Gambar 8. Grafik perbandingan data aktual dengan hasil peramalan jumlah produksi kopi di Indonesia Model Terbaik ANN arsitektur *5 neuron*

Berdasarkan Gambar 8, secara visual hasil peramalan memperlihatkan pola musiman yang sejalan dengan data historis, yaitu produksi meningkat secara bertahap di awal tahun, mencapai puncak pada Juni–Juli, lalu kembali menurun menjelang akhir tahun. Pola ini menunjukkan bahwa model ANN mampu menangkap karakteristik musiman data produksi kopi.

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* 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* 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*.

Jurnal Gaussian_lanjutan

ORIGINALITY REPORT

18%
SIMILARITY INDEX

PRIMARY SOURCES

1	repo-dosen.ulm.ac.id Internet	111 words — 2%
2	repository.its.ac.id Internet	93 words — 2%
3	ejournal3.undip.ac.id Internet	70 words — 2%
4	jurnal.fmipa.unmul.ac.id Internet	46 words — 1%
5	journal.unugiri.ac.id Internet	45 words — 1%
6	"Perbandingan Analisis Diskriminan dan Analisis Regresi Logistik Ordinal dalam Prediksi Klasifikasi Kondisi Kesehatan Bank", 'Universitas Udayana' Internet	44 words — 1%
7	digilib.uinsa.ac.id Internet	25 words — 1%
8	docplayer.info Internet	25 words — 1%
9	lebesgue.lppmbinabangsa.id Internet	24 words — 1%
10	online-journal.unja.ac.id Internet	23 words — 1%
11	www.scribd.com Internet	19 words — < 1%
	digilib.its.ac.id	

12	Internet	18 words — < 1%
13	jurnal.untan.ac.id Internet	17 words — < 1%
14	edoc.pub Internet	16 words — < 1%
15	jurnal.univrab.ac.id Internet	16 words — < 1%
16	subset.id Internet	16 words — < 1%
17	repository.uin-suska.ac.id Internet	14 words — < 1%
18	www.coursehero.com Internet	14 words — < 1%
19	ejurnal.ung.ac.id Internet	12 words — < 1%
20	www.isca.in Internet	12 words — < 1%
21	www.slideshare.net Internet	12 words — < 1%
22	adoc.pub Internet	11 words — < 1%
23	ar.scribd.com Internet	11 words — < 1%
24	Deswita Istiyanti, Erlyne Nadhilah Widyaningrum, Mitha Rabiyatul Nufus, Chandrawati Chandrawati. "Peramalan Harga Beras Mingguan di Kalimantan Timur Menggunakan Metode Singular Spectrum Analysis", Jurnal Statistika dan Komputasi, 2025 Crossref	10 words — < 1%
25	M Ilmi Alfaridzi, Rahmad Gunawan, Haris Alfian, Muhammad Fitter Mirano, Hayatun Nazifah, Sri Wahyuni, Kevanda Sondani Illahi.	10 words — < 1%

"Perbandingan model SARIMA dan Prophet dalam memprediksi jumlah kunjungan wisatawan mancanegara ke Indonesia berdasarkan data deret waktu bulanan", Jurnal CoSciTech (Computer Science and Information Technology), 2025
Crossref

26	ejournal.uin-suska.ac.id Internet	10 words — < 1%
27	jesicasari23.blogspot.com Internet	10 words — < 1%
28	Muh. Niswar, Muh. Tamrin, Haslindah Haslindah, Pratiwi Ramlan. "Analisis Forecasting Pengisian Tabung Gas Menggunakan Metode Time Series Pada Stasiun Pengisian dan Pengangkutan Bulk Elpiji (SPPBE) PT. Sinar Energi Sulawesi", JEMSI (Jurnal Ekonomi, Manajemen, dan Akuntansi), 2025 Crossref	9 words — < 1%
29	journals.unpad.ac.id Internet	9 words — < 1%
30	Faqihuddin Al Anshori. "Peramalan Harga Saham BCA Menggunakan Long Short Term Memory (LSTM)", Jurnal Dinamika Informatika, 2024 Crossref	8 words — < 1%
31	fr.scribd.com Internet	8 words — < 1%
32	repository.ub.ac.id Internet	8 words — < 1%
33	www.ie.ufrj.br Internet	8 words — < 1%
34	Ni Putu Nanik Hendayanti, Maulida Nurhidayati. "Perbandingan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA) dengan Support Vector Regression (SVR) dalam Memprediksi Jumlah Kunjungan Wisatawan Mancanegara ke Bali", Jurnal Varian, 2020 Crossref	7 words — < 1%

EXCLUDE QUOTES	OFF	EXCLUDE MATCHES	OFF
EXCLUDE BIBLIOGRAPHY	ON		