

# Pendekatan *Hybrid VARIMA–ANN* untuk Peramalan Multivariat Data Cuaca Bulanan di Provinsi Gorontalo

Nur Anggraini T. Ali, Djihad Wungguli, dan Isran K. Hasan



Volume 14, Issue 1, Pages 219–237, April 2026

Diterima 23 Januari 2026, Direvisi 11 April 2026, Disetujui 24 April 2026, Diterbitkan 26 April 2026

To Cite this Article : N. A. T. Ali, D. Wungguli, dan I. K. Hasan, "Pendekatan *Hybrid VARIMA–ANN* untuk Peramalan Multivariat Data Cuaca Bulanan di Provinsi Gorontalo", *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 14, no. 1, pp. 219–237, 2026, <https://doi.org/10.37905/euler.v14i1.37513>

© 2026 by author(s)

## JOURNAL INFO • EULER : JURNAL ILMIAH MATEMATIKA, SAINS DAN TEKNOLOGI



- Homepage : <http://ejurnal.ung.ac.id/index.php/euler/index>
- Journal Abbreviation : Euler J. Ilm. Mat. Sains dan Teknol.
- Frequency : Three times a year
- Publication Language : English (preferable), Indonesia
- DOI : <https://doi.org/10.37905/euler>
- Online ISSN : 2776-3706
- License : Creative Commons Attribution-NonCommercial 4.0 International License
- Publisher : Department of Mathematics, Universitas Negeri Gorontalo
- Country : Indonesia
- OAI Address : <http://ejurnal.ung.ac.id/index.php/euler/oai>
- Google Scholar ID : QF\_r-gAAAAJ
- Email : [euler@ung.ac.id](mailto:euler@ung.ac.id)

## JAMBURA JOURNAL • FIND OUR OTHER JOURNALS



Jambura Journal of Biomathematics



Jambura Journal of Mathematics



Jambura Journal of Mathematics Education



Jambura Journal of Probability and Statistics

# Pendekatan *Hybrid* VARIMA–ANN untuk Peramalan Multivariat Data Cuaca Bulanan di Provinsi Gorontalo

Nur Anggraini T. Ali<sup>1,\*</sup>, Djihad Wungguli<sup>1</sup>, dan Isran K. Hasan<sup>1</sup>

<sup>1</sup>Jurusan Matematika, Universitas Negeri Gorontalo, Gorontalo 96554, Indonesia

## ARTICLE HISTORY

Diterima 23 Januari 2026  
Direvisi 11 April 2026  
Disetujui 24 April 2026  
Diterbitkan 26 April 2026

## KATA KUNCI

Peramalan cuaca  
Deret waktu multivariat  
VARIMA  
Artificial Neural Network  
Model hybrid

## KEYWORDS

Weather forecasting  
Multivariate time series  
VARIMA  
Artificial Neural Network  
Hybrid model

**ABSTRAK.** Peramalan deret waktu multivariat penting untuk memahami keterkaitan antarparameter cuaca. Penelitian ini bertujuan membangun model peramalan multivariat menggunakan pendekatan hybrid Vector Autoregressive Integrated Moving Average (VARIMA)–Artificial Neural Network (ANN) dengan algoritma backpropagation pada data cuaca Provinsi Gorontalo periode 2015–2023, yang mencakup suhu udara, kelembapan udara, dan kecepatan angin. Data dibagi menjadi data pelatihan (2015–2021) dan data pengujian (2022–2023). Model VARIMA digunakan untuk memodelkan komponen linier, sedangkan residual dari model VARIMA selanjutnya dimodelkan menggunakan ANN untuk menangkap pola nonlinier. Orde model VARIMA dipilih berdasarkan nilai Akaike Information Criterion (AIC) terkecil, sedangkan kinerja model dievaluasi menggunakan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model terbaik yang diperoleh adalah VARIMA(5,1,1)–ANN(18,9,3), dengan nilai MAPE masing-masing sebesar 1,32% untuk suhu udara, 20,54% untuk kelembapan udara, dan 21,96% untuk kecepatan angin. Hasil tersebut menunjukkan bahwa pendekatan hybrid VARIMA–ANN memberikan kinerja peramalan yang baik dan berpotensi menjadi alternatif dalam peramalan cuaca multivariat.

**ABSTRACT.** Multivariate time series forecasting is essential for understanding the interrelationships among weather parameters. This study aims to develop a multivariate forecasting model using a hybrid Vector Autoregressive Integrated Moving Average (VARIMA)–Artificial Neural Network (ANN) approach with the backpropagation algorithm, applied to weather data from Gorontalo Province over the 2015–2023 period, including air temperature, humidity, and wind speed. The data were divided into training data (2015–2021) and testing data (2022–2023). The VARIMA model was employed to capture the linear component, while the residuals from the VARIMA model were subsequently modeled using ANN to capture nonlinear patterns. The order of the VARIMA model was determined based on the smallest Akaike Information Criterion (AIC) value, while model performance was evaluated using Mean Absolute Percentage Error (MAPE). The results indicate that the best-performing model is VARIMA(5,1,1)–ANN(18,9,3), with MAPE values of 1.32% for air temperature, 20.54% for humidity, and 21.96% for wind speed. These findings suggest that the hybrid VARIMA–ANN approach provides good forecasting performance and has the potential to serve as an alternative method for multivariate weather forecasting.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. **Editorial of EULER:** Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

## 1. Pendahuluan

Cuaca merupakan kondisi atmosfer jangka pendek yang bersifat dinamis dan dipengaruhi oleh interaksi kompleks antarparameter meteorologi, seperti suhu udara, kelembapan udara, dan kecepatan angin [1]. Ketidakpastian dan fluktuasi cuaca, terutama di wilayah tropis seperti Indonesia, dapat menimbulkan dampak yang signifikan terhadap berbagai sektor, termasuk pertanian, transportasi, energi, dan mitigasi bencana [2, 3]. Oleh karena itu, peramalan cuaca yang akurat menjadi penting sebagai dasar pengambilan keputusan berbasis data serta upaya antisipasi dini [4].

\*Penulis Korespondensi.

Data cuaca umumnya berbentuk deret waktu yang tersusun secara berkala dan membentuk pola historis yang kompleks. Karakteristik data ini tidak hanya menunjukkan struktur linier, seperti tren dan musiman, tetapi juga dinamika nonlinier yang dipengaruhi oleh proses atmosfer yang kompleks [5–9]. Selain itu, parameter cuaca seperti suhu udara, kelembapan udara, dan kecepatan angin tidak bersifat independen, melainkan saling berinteraksi secara simultan. Dengan demikian, pendekatan multivariat lebih tepat digunakan dibandingkan pendekatan univariat, karena mampu memodelkan keterkaitan antarvariabel secara lebih komprehensif [10, 11]. Pendekatan deret waktu juga telah banyak diterapkan dalam berbagai studi peramalan, seperti peramalan hasil produksi pertanian menggunakan metode *Double Moving Average* yang menunjukkan kinerja yang baik dalam menangkap pola data historis [12].

Salah satu metode yang banyak digunakan untuk peramalan deret waktu multivariat adalah *Vector Autoregressive Integrated Moving Average* (VARIMA). Model ini merupakan pengembangan *Autoregressive Integrated Moving Average* (ARIMA) dalam bentuk vektor yang memungkinkan analisis hubungan dinamis antarvariabel. Sejumlah penelitian telah menunjukkan bahwa VARIMA efektif digunakan dalam berbagai kasus, seperti peramalan inflasi dan suku bunga [13], data iklim [14], curah hujan [15], indeks pencemaran udara [16], indeks harga konsumen [17], dan debit air [18]. Meskipun demikian, VARIMA memiliki keterbatasan karena pada dasarnya dibangun atas asumsi hubungan linier, sehingga kemampuannya menjadi terbatas ketika dihadapkan pada pola nonlinier yang sering muncul pada data cuaca [19, 20].

Di sisi lain, *Artificial Neural Network* (ANN), khususnya dengan algoritma *backpropagation*, dikenal memiliki kemampuan yang baik dalam memodelkan hubungan nonlinier yang kompleks. ANN telah digunakan secara luas dalam berbagai studi peramalan dan menunjukkan kinerja yang baik [21, 22]. Namun, ANN umumnya tidak secara eksplisit memodelkan struktur ketergantungan multivariat antarvariabel sebagaimana VARIMA. Akibatnya, apabila digunakan secara tunggal, informasi hubungan simultan antarparameter cuaca berpotensi tidak dimanfaatkan secara optimal.

Perkembangan studi peramalan menunjukkan bahwa pendekatan *hybrid* yang menggabungkan model statistik dan *machine learning* dapat memberikan hasil yang lebih baik karena memanfaatkan keunggulan masing-masing metode. Dalam pendekatan ini, model statistik digunakan untuk menangkap pola linier dan hubungan antarvariabel, sedangkan model *machine learning* digunakan untuk memodelkan pola nonlinier yang masih tersisa pada residual. Pendekatan *residual-based hybrid* dilaporkan mampu meningkatkan akurasi prediksi secara signifikan [23]. Selain itu, kombinasi model VAR dengan *neural network* juga telah menunjukkan peningkatan kinerja pada peramalan data polusi [24]. Di sisi lain, metode *machine learning* seperti *K-Nearest Neighbor* dan *Random Forest* juga telah digunakan dalam berbagai studi klasifikasi dan prediksi, termasuk dengan penerapan seleksi fitur untuk meningkatkan kinerja model [25]. Meskipun demikian, penerapan model *hybrid* VARIMA–ANN pada data cuaca multivariat di Indonesia masih relatif terbatas, khususnya untuk wilayah tropis seperti Provinsi Gorontalo.

Berdasarkan kondisi tersebut, penelitian ini mengusulkan model *hybrid* VARIMA–ANN untuk peramalan deret waktu multivariat pada data cuaca Provinsi Gorontalo, yang meliputi suhu udara, kelembapan udara, dan kecepatan angin. Dalam model ini, VARIMA digunakan untuk memodelkan komponen linier dan hubungan antarvariabel, sedangkan ANN dengan algoritma *backpropagation* digunakan untuk memodelkan pola nonlinier pada residual VARIMA. Pendekatan ini diharapkan dapat menghasilkan model peramalan yang lebih akurat dibandingkan penggunaan model linier tunggal.

Urgensi penelitian ini terletak pada kebutuhan akan sistem peramalan cuaca yang lebih akurat untuk mendukung pengambilan keputusan pada sektor pertanian, perikanan, dan manajemen bencana di Provinsi Gorontalo. Oleh karena itu, penelitian ini bertujuan untuk: (1) membangun model *hybrid* VARIMA–ANN untuk peramalan parameter cuaca multivariat di Provinsi Gorontalo; dan (2) mengevaluasi kinerja model menggunakan *Mean Absolute Percentage Error* (MAPE) pada data pengujian.

## 2. Metode

### 2.1. Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) Provinsi Gorontalo dan Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Data terdiri atas tiga parameter cuaca, yaitu suhu udara, kelembapan udara, dan kecepatan angin. Seluruh data disusun dalam bentuk deret waktu bulanan dari Januari 2015 hingga Desember 2023. Secara ringkas, karakteristik data penelitian disajikan pada **Tabel 1**.

**Tabel 1.** Karakteristik data penelitian

Komponen	Keterangan
Jenis data	Data sekunder
Sumber data	BPS Provinsi Gorontalo dan BMKG
Variabel	Suhu udara, kelembapan udara, kecepatan angin
Frekuensi data	Bulanan
Periode pengamatan	Januari 2015–Desember 2023
Jumlah observasi per variabel	108
Total data	324
Data pelatihan	Januari 2015–Desember 2021 (84 observasi)
Data pengujian	Januari 2022–Desember 2023 (24 observasi)
Perangkat lunak	RStudio

Data pelatihan digunakan untuk pembentukan model dan estimasi parameter, sedangkan data pengujian digunakan untuk mengevaluasi hasil peramalan.

### 2.2. Tahapan Analisis

Tahapan analisis dalam penelitian ini meliputi uji stasioneritas, identifikasi model VARIMA, estimasi parameter, pemilihan model terbaik, uji diagnostik residual, pembentukan model ANN berbasis residual, pembentukan model *hybrid* VARIMA–ANN, dan evaluasi akurasi peramalan.

#### 2.2.1. Uji stasioneritas

Uji stasioneritas dilakukan terhadap varians dan rata-rata data. Stasioneritas dalam varians diperiksa menggunakan transformasi Box–Cox, sedangkan stasioneritas dalam rata-rata diuji menggunakan *Augmented Dickey–Fuller* (ADF). Data dikatakan stasioner apabila rataan dan variansnya relatif konstan sepanjang waktu [26, 27]. Transformasi Box–Cox dinyatakan sebagai berikut:

$$T(Z_t) = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda}, & \lambda \neq 0, \\ \ln(Z_t), & \lambda = 0, \end{cases} \quad (1)$$

dengan  $Z_t$  menyatakan nilai variabel pada waktu ke- $t$  dan  $\lambda$  menyatakan parameter transformasi. Bentuk transformasi berdasarkan nilai  $\lambda$  disajikan pada **Tabel 2**.

**Tabel 2.** Bentuk transformasi Box–Cox berdasarkan nilai  $\lambda$

Nilai $\lambda$	Transformasi
-1	$\frac{1}{Z_t}$
-0.5	$\frac{1}{\sqrt{Z_t}}$
0	$\ln(Z_t)$
0.5	$\sqrt{Z_t}$
1	$Z_t$

Setelah stasioneritas dalam varians tercapai, stasioneritas dalam rata-rata diperiksa menggunakan uji ADF dengan hipotesis:

$$\begin{aligned}
 H_0 &: \gamma \geq 0 \quad (\text{data tidak stasioner dalam rata-rata}), \\
 H_1 &: \gamma < 0 \quad (\text{data stasioner dalam rata-rata}).
 \end{aligned}$$

Statistik uji ADF dirumuskan sebagai berikut [28]:

$$\tau = \frac{\hat{\gamma} - \gamma}{SE(\hat{\gamma})}. \tag{2}$$

Keputusan diambil dengan menolak  $H_0$  apabila  $p\text{-value} < \alpha$  pada taraf signifikansi 5%. Jika data belum stasioner dalam rata-rata, maka dilakukan *differencing* orde pertama sebagai berikut [27].

$$W_t = Z_t - Z_{t-1}, \tag{3}$$

dengan  $W_t$  menyatakan data hasil *differencing*.

### 2.2.2. Identifikasi model VARIMA

Identifikasi orde model VARIMA dilakukan menggunakan *Matrix Autocorrelation Function* (MACF) dan *Matrix Partial Autocorrelation Function* (MPACF). Jika terdapat vektor deret waktu  $Z_1, Z_2, \dots, Z_n$ , maka matriks korelasi sampel pada lag ke- $k$  dinyatakan sebagai:

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)],$$

dengan elemen korelasi silang sampel antara komponen ke- $i$  dan ke- $j$  dirumuskan sebagai berikut [27]:

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,t+k} - \bar{Z}_j)}{[\sum_{t=1}^n (Z_{i,t} - \bar{Z}_i)^2 \sum_{t=1}^n (Z_{j,t} - \bar{Z}_j)^2]^{1/2}}.$$

Nilai MACF digunakan untuk membantu mengidentifikasi orde *moving average* (MA), sedangkan MPACF digunakan untuk membantu mengidentifikasi orde *autoregressive* (AR). Untuk mempermudah identifikasi pola, nilai MACF dan MPACF dinyatakan dengan simbol (+), (−), dan (.). Simbol (+) menunjukkan korelasi positif signifikan yang lebih besar dari dua kali taksiran standar error, simbol (−) menunjukkan korelasi negatif signifikan yang lebih kecil dari dua kali taksiran standar error, sedangkan simbol (.) menunjukkan tidak adanya korelasi yang signifikan pada lag tertentu [14].

### 2.2.3. Estimasi parameter VARIMA

Estimasi parameter model VARIMA dilakukan menggunakan metode *Maximum Likelihood Estimation* (MLE). Pada model multivariat, *error* diasumsikan mengikuti distribusi normal multivariat dengan matriks kovarian  $\Sigma$  yang bersifat definit positif [29, 30]. Fungsi likelihood untuk

error multivariat dapat dituliskan sebagai berikut:

$$l(\boldsymbol{\beta}, \Sigma | \mathbf{Y}) = \prod_{i=1}^m f(\boldsymbol{\beta}, \Sigma | Y_i), \quad (4)$$

dengan estimator parameter  $\boldsymbol{\beta}$  diberikan oleh:

$$\hat{\boldsymbol{\beta}} = (X^\top \Sigma^{-1} X)^{-1} X^\top \Sigma^{-1} Y.$$

#### 2.2.4. Pemilihan model terbaik VARIMA

Model terbaik dipilih berdasarkan nilai Akaike Information Criterion (AIC) terkecil. Kriteria ini mempertimbangkan keseimbangan antara goodness-of-fit dan kompleksitas model [17, 28]. Rumus AIC yang digunakan adalah:

$$AIC(p, q) = \ln |\Sigma| + \frac{2k^2(p + q)}{T}, \quad (5)$$

dengan  $T$  menyatakan banyaknya pengamatan,  $k$  banyaknya variabel dalam model,  $p$  orde autoregressive,  $q$  orde moving average, dan  $\Sigma$  matriks kovarian residual.

#### 2.2.5. Uji diagnostik residual

Setelah model VARIMA terbaik diperoleh, residual model diuji menggunakan statistik Ljung–Box untuk memastikan bahwa residual bersifat *white noise*. Statistik uji yang digunakan dirumuskan sebagai berikut [17].

$$Q = T(T + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{T - k}, \quad (6)$$

dengan  $T$  menyatakan banyaknya data,  $K$  banyaknya lag yang diuji, dan  $\hat{\rho}_k$  dugaan auto-korelasi residual pada lag ke- $k$ . Residual dikatakan memenuhi asumsi white noise apabila  $p$ -value  $> \alpha$ .

#### 2.2.6. Pembentukan model ANN berbasis residual

Residual dari model VARIMA terbaik selanjutnya digunakan sebagai input pada Artificial Neural Network (ANN) dengan algoritma backpropagation. Arsitektur ANN terdiri atas input layer, hidden layer, dan output layer. Input layer dibentuk dari residual berdasarkan lag signifikan hasil identifikasi MACF dan MPACF, output layer ditentukan berdasarkan jumlah variabel yang diamati, sedangkan jumlah neuron pada hidden layer dipilih menggunakan pendekatan trial and error dari 1 sampai 10 neuron.

Validasi model ANN dilakukan menggunakan Root Mean Squared Error (RMSE). Model ANN terbaik dipilih berdasarkan nilai RMSE terkecil, karena nilai RMSE yang lebih kecil menunjukkan tingkat kesalahan peramalan yang lebih rendah.

#### 2.2.7. Pembentukan model hybrid VARIMA–ANN

Setelah model VARIMA dan ANN terbaik diperoleh, keduanya digabungkan untuk membentuk model *hybrid* VARIMA–ANN. Model VARIMA digunakan untuk memodelkan komponen linier, sedangkan ANN digunakan untuk memodelkan komponen nonlinier yang tersisa pada residual. Persamaan umum model VARIMA dituliskan sebagai berikut:

$$Y_t = \phi_p(B)Y_t + \alpha_t + \theta_q(B)\alpha_t,$$

sedangkan bentuk umum model ANN dinyatakan sebagai:

$$\hat{y}_t = \sum_{j=1}^p w_j \frac{1}{1 + e^{-v_{oj}} + \sum_{i=1}^q x_i v_{ij}} + w_0.$$

### 2.2.8. Evaluasi akurasi peramalan

Akurasi hasil peramalan model *hybrid* dievaluasi menggunakan Mean Absolute Percentage Error (MAPE) [31, 32]. Nilai MAPE dihitung menggunakan rumus:

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\%, \quad (7)$$

dengan  $N$  menyatakan banyaknya data ramalan,  $Y_t$  data aktual, dan  $\hat{Y}_t$  data hasil ramalan. Kriteria interpretasi nilai MAPE disajikan pada **Tabel 3**.

**Tabel 3.** Kriteria interpretasi nilai MAPE

Nilai MAPE	Kriteria
$\leq 10\%$	Sangat baik
$10\% < MAPE \leq 20\%$	Baik
$20\% < MAPE < 50\%$	Cukup baik
$\geq 50\%$	Sangat tidak baik

Suatu model dikatakan memiliki kinerja sangat baik apabila nilai MAPE berada di bawah 10%, dan dikatakan baik apabila nilai MAPE berada pada rentang 10% hingga 20%.

## 3. Hasil dan Pembahasan

Pada bab ini disajikan hasil analisis data serta pembahasan terhadap tahapan pemodelan yang telah dilakukan untuk membangun model *hybrid* VARIMA–ANN pada data cuaca multivariat di Provinsi Gorontalo. Pembahasan diawali dengan pengujian stasioneritas data sebagai prasyarat utama dalam pemodelan VARIMA, kemudian dilanjutkan dengan identifikasi model, estimasi parameter, pemilihan model terbaik, pengujian residual, pembentukan model ANN berbasis residual, hingga evaluasi akurasi model *hybrid* yang diperoleh. Penyajian hasil secara bertahap ini bertujuan untuk menunjukkan bahwa model yang dibangun tidak hanya memenuhi asumsi statistik yang diperlukan, tetapi juga memiliki kemampuan yang memadai dalam menghasilkan peramalan parameter cuaca.

### 3.1. Uji Stasioneritas


Dalam proses pemodelan, uji stasioneritas dilakukan untuk memastikan bahwa data memenuhi asumsi dasar pada pemodelan VARIMA. Data deret waktu dikatakan stasioner apabila memiliki varians dan rata-rata yang relatif konstan sepanjang waktu. Jika data belum stasioner, maka diperlukan transformasi atau *differencing* agar memenuhi asumsi pemodelan [11]. Pengujian stasioneritas dalam penelitian ini dilakukan melalui uji stasioneritas dalam varians menggunakan transformasi Box–Cox pada **pers. (1)** dan uji stasioneritas dalam rata-rata menggunakan uji Augmented Dickey–Fuller (ADF) pada **pers. (2)**.

#### 3.1.1. Stasioneritas dalam Varians

Uji stasioneritas dalam varians dilakukan menggunakan transformasi Box–Cox. Hasil uji untuk masing-masing parameter cuaca disajikan pada **Gambar 1–Gambar 6**.


## Suhu udara

Sebelum dilakukan pemodelan, data suhu udara terlebih dahulu diuji untuk mengetahui apakah varians data telah memenuhi asumsi stasioneritas. Pengujian ini penting karena kestabilan varians merupakan salah satu prasyarat dalam pembentukan model VARIMA, sehingga pola data yang dianalisis tidak dipengaruhi oleh perubahan dispersi yang tidak konstan sepanjang waktu. Hasil uji awal pada **Gambar 1** menunjukkan bahwa nilai parameter transformasi yang diperoleh sebesar 8,462083, sehingga  $\lambda \neq 1$ . Berdasarkan hasil tersebut, dapat diindikasikan bahwa data suhu udara belum stasioner dalam varians, yang berarti sebaran data masih mengalami perubahan dan belum stabil dari satu periode ke periode lainnya. Kondisi ini menunjukkan bahwa data belum sepenuhnya memenuhi asumsi awal untuk pemodelan deret waktu multivariat.



**Gambar 1.** Plot data pelatihan suhu udara untuk uji stasioneritas dalam varians sebelum transformasi

Oleh karena itu, dilakukan transformasi *Box–Cox* untuk menstabilkan varians data. Setelah transformasi diterapkan, hasil pada **Gambar 2** menunjukkan bahwa nilai  $\lambda = 1$ , sehingga data suhu udara dapat dinyatakan telah stasioner dalam varians dan tidak memerlukan transformasi lanjutan. Hasil ini menunjukkan bahwa transformasi yang dilakukan berhasil memperbaiki struktur variasi data, sehingga data suhu udara menjadi lebih layak untuk digunakan pada tahap analisis berikutnya, khususnya pengujian stasioneritas dalam rata-rata dan identifikasi model VARIMA. Dengan varians yang telah stabil, proses pemodelan diharapkan dapat menghasilkan estimasi parameter yang lebih baik dan peramalan yang lebih andal.




**Gambar 2.** Plot data pelatihan suhu udara untuk uji stasioneritas dalam varians setelah transformasi *Box–Cox*

## Kelembapan udara


Pengujian yang sama kemudian diterapkan pada data kelembapan udara untuk memastikan apakah varians data telah memenuhi asumsi stasioneritas sebelum dilakukan pemodelan lebih lanjut. Pengujian ini penting karena varians yang tidak stabil dapat memengaruhi

ketepatan identifikasi pola data serta menurunkan kualitas estimasi parameter pada model VARIMA. Berdasarkan **Gambar 3**, nilai parameter transformasi awal yang diperoleh sebesar 7,417155, sehingga  $\lambda \neq 1$ . Hasil tersebut mengindikasikan bahwa data kelembapan udara belum stasioner dalam varians, yang berarti tingkat penyebaran data masih berubah-ubah antarperiode dan belum menunjukkan kestabilan yang memadai untuk analisis deret waktu.



**Gambar 3.** Plot data pelatihan kelembapan udara untuk uji stasioneritas dalam varians sebelum transformasi

Untuk mengatasi kondisi tersebut, dilakukan transformasi *Box–Cox* dengan tujuan menstabilkan varians data. Setelah transformasi diterapkan, hasil pada **Gambar 4** menunjukkan bahwa nilai  $\lambda = 1$ . Dengan demikian, data kelembapan udara dapat dinyatakan telah memenuhi asumsi stasioneritas dalam varians. Hasil ini menunjukkan bahwa transformasi yang dilakukan berhasil memperbaiki struktur variasi data, sehingga data kelembapan udara menjadi lebih sesuai untuk tahap analisis berikutnya, khususnya pengujian stasioneritas dalam rata-rata dan identifikasi model VARIMA. Varians yang telah stabil juga memberikan dasar yang lebih baik untuk memperoleh model peramalan yang lebih andal.




**Gambar 4.** Plot data pelatihan kelembapan udara untuk uji stasioneritas dalam varians setelah transformasi *Box–Cox*

### Kecepatan angin


Selanjutnya, uji stasioneritas dalam varians dilakukan pada data kecepatan angin untuk memastikan apakah varians data telah stabil sebelum digunakan dalam tahap pemodelan. Pengujian ini penting karena varians yang tidak konstan dapat menyebabkan pola data menjadi kurang representatif dan berpotensi memengaruhi ketepatan estimasi parameter pada model VARIMA. Hasil pada **Gambar 5** menunjukkan bahwa nilai parameter transformasi awal sebesar  $-0,44664388$ , sehingga  $\lambda \neq 1$ . Hasil tersebut mengindikasikan bahwa data kecepatan angin belum stasioner dalam varians, yang berarti tingkat penyebaran data masih berfluktuasi antarperiode dan belum menunjukkan kestabilan yang memadai untuk analisis deret waktu.

Untuk mengatasi kondisi tersebut, diterapkan transformasi *Box–Cox* dengan tujuan men-



**Gambar 5.** Plot data pelatihan kecepatan angin untuk uji stasioneritas dalam varians sebelum transformasi

stabilkan varians data. Setelah transformasi dilakukan, hasil pada **Gambar 6** menunjukkan bahwa nilai  $\lambda = 1$ , sehingga data kecepatan angin dapat dinyatakan telah stasioner dalam varians. Hasil ini menunjukkan bahwa transformasi yang diterapkan berhasil memperbaiki struktur variasi data, sehingga data kecepatan angin menjadi lebih layak untuk digunakan pada tahap analisis berikutnya, khususnya pengujian stasioneritas dalam rata-rata dan identifikasi model VARIMA. Dengan varians yang telah stabil, proses pemodelan diharapkan dapat menghasilkan estimasi parameter dan hasil peramalan yang lebih andal.



**Gambar 6.** Plot data pelatihan kecepatan angin untuk uji stasioneritas dalam varians setelah transformasi Box-Cox

Setelah ketiga variabel memenuhi stasioneritas dalam varians, pengujian selanjutnya dilakukan terhadap stasioneritas dalam rata-rata menggunakan uji ADF pada **pers. (2)**.

### 3.1.2. Stasioneritas dalam Rata-rata

Setelah seluruh variabel memenuhi asumsi stasioneritas dalam varians, tahapannya adalah menguji stasioneritas dalam rata-rata. Pengujian ini penting karena model VARIMA mensyaratkan data yang memiliki nilai tengah relatif konstan sepanjang waktu, sehingga hubungan antarvariabel dapat dimodelkan secara lebih stabil. Apabila rata-rata data masih berubah dari satu periode ke periode lainnya, maka pola yang terbentuk dapat mencerminkan kecenderungan jangka panjang atau dinamika nonstasioner yang berpotensi mengganggu proses identifikasi dan estimasi model.

Dalam penelitian ini, stasioneritas dalam rata-rata diuji menggunakan uji *Augmented Dickey-Fuller* (ADF) sebagaimana dirumuskan pada **pers. (2)**. Uji ini digunakan untuk mendeteksi keberadaan akar unit pada deret waktu, di mana keberadaan akar unit menunjukkan bahwa data belum stasioner dalam rata-rata. Jika hasil pengujian menunjukkan bahwa data belum stasioner, maka dilakukan *differencing* menggunakan **pers. (3)** untuk menghilangkan kecenderungan nonstasioner dan memperoleh deret yang lebih stabil. Hasil uji ADF sebelum dan sesudah *differencing* disajikan pada **Tabel 4**.

**Tabel 4.** Hasil uji ADF sebelum dan sesudah *differencing*

Variabel	Sebelum <i>differencing</i>	Sesudah <i>differencing</i>
Suhu udara	0,187	0,01
Kelembapan udara	0,293	0,01
Kecepatan angin	0,360	0,01

Berdasarkan **Tabel 4**, sebelum *differencing* nilai *p-value* untuk suhu udara, kelembapan udara, dan kecepatan angin masing-masing sebesar 0,187, 0,293, dan 0,360. Karena seluruh nilai *p-value* lebih besar dari 0,05, maka ketiga variabel belum stasioner dalam rata-rata. Oleh karena itu, dilakukan *differencing* orde pertama menggunakan **pers. (3)**.

Setelah *differencing* satu kali, nilai *p-value* untuk ketiga variabel masing-masing sebesar 0,01. Nilai tersebut lebih kecil dari 0,05, sehingga dapat disimpulkan bahwa seluruh variabel telah stasioner dalam rata-rata. Dengan demikian, data telah memenuhi asumsi stasioneritas dan dapat digunakan pada tahap identifikasi model VARIMA.

### 3.2. Identifikasi Model

Model VARIMA diidentifikasi menggunakan skema *Multivariate Autocorrelation Function* (MACF) dan *Multivariate Partial Autocorrelation Function* (MPACF) pada data hasil *differencing* dari variabel parameter cuaca, yaitu suhu udara (SU), kelembapan udara (KU), dan kecepatan angin (KA).

MACF digunakan untuk mengidentifikasi pola korelasi multivariat antarvariabel, sedangkan MPACF digunakan untuk mengidentifikasi korelasi parsial setelah pengaruh *lag* sebelumnya dieliminasi. Analisis kedua skema ini bertujuan untuk menentukan orde model VARIMA, khususnya dalam mengidentifikasi orde *autoregressive* (*p*) dan *moving average* (*q*). Hasil analisis skema MACF dan MPACF disajikan pada **Tabel 5** dan **Tabel 6**.

**Tabel 5.** Skema MACF parameter cuaca

Variabel/ <i>lag</i>	1	2	3	4	5	6	7	8	9	10	11	12
SU	−.	...	...	...	...	−.	+.	−.	...	...	...	+.
KU	. −.	+.	...	−.	...	+.	+.	...	−.	...	−.	...
KA	+.	...	...	...	+.	−.	...	...	−.	...	...	...

**Tabel 6.** Skema MPACF parameter cuaca

Variabel/ <i>lag</i>	1	2	3	4	5	6	7	8	9	10	11	12
SU	...	−.	...	...	+.	−.	...	−.	...	...	−.	+.
KU	...	+.	...	−.	...	+.	...	...	−.	...	−.	+.
KA	...	...	...	...	+.	−.	+.	...	−.	...	...	−.

Berdasarkan **Tabel 5** dan **Tabel 6**, model sementara yang terbentuk adalah VARIMA(2, 1, 1), VARIMA(2, 1, 6), VARIMA(2, 1, 7), VARIMA(5, 1, 1), dan VARIMA(6, 1, 1). Tanda (+) menunjukkan nilai korelasi positif signifikan yang lebih besar dari dua kali taksiran *standard error*. Tanda (−) menunjukkan nilai korelasi negatif signifikan yang lebih kecil dari dua kali taksiran *standard error*. Adapun tanda (.) menunjukkan tidak adanya hubungan korelasi yang signifikan antara masing-masing variabel pada *lag* tertentu.

### 3.3. Estimasi Parameter

Estimasi parameter model dilakukan menggunakan metode *Maximum Likelihood Estimation* (MLE) pada pers. (4). Tahap ini bertujuan untuk memperoleh estimasi parameter sekaligus menguji signifikansi parameter pada setiap kandidat model. Identifikasi model menggunakan MACF dan MPACF pada Tabel 5 dan Tabel 6 menghasilkan lima model sementara, yaitu VARIMA(2, 1, 1), VARIMA(2, 1, 6), VARIMA(2, 1, 7), VARIMA(5, 1, 1), dan VARIMA(6, 1, 1).

Pengujian signifikansi parameter dilakukan untuk mengidentifikasi parameter yang berpengaruh terhadap model. Hipotesis alternatif yang digunakan adalah bahwa parameter model signifikan apabila nilai *p-value* lebih kecil dari taraf signifikansi 5% atau 0,05. Hasil estimasi menunjukkan bahwa model VARIMA(2, 1, 1) memiliki dua parameter yang signifikan. Model VARIMA(2, 1, 6) dan VARIMA(2, 1, 7) tidak memiliki parameter yang signifikan karena menghasilkan nilai *p-value* berupa *NaN*, yang menunjukkan bahwa parameter model tidak dapat dihitung secara numerik. Dengan demikian, kedua model tersebut dinyatakan tidak valid. Sementara itu, model VARIMA(5, 1, 1) memiliki empat parameter yang signifikan, sedangkan model VARIMA(6, 1, 1) memiliki lima parameter yang signifikan.

### 3.4. Model Terbaik VARIMA

Pemilihan model terbaik dilakukan menggunakan nilai *Akaike Information Criterion* (AIC) dari beberapa kandidat model VARIMA yang diperoleh pada tahap estimasi parameter. Kriteria pemilihan model terbaik didasarkan pada nilai AIC terkecil, sesuai dengan pers. (5). Hasil penentuan model terbaik VARIMA disajikan pada Tabel 7.

**Tabel 7.** Penentuan model terbaik VARIMA berdasarkan nilai AIC

No.	Model	AIC
1	VARIMA(2, 1, 1)	-1,054211
2	VARIMA(2, 1, 6)	39,975948
3	VARIMA(2, 1, 7)	178,191207
4	VARIMA(5, 1, 1)	-1,068289
5	VARIMA(6, 1, 1)	-0,957287

Berdasarkan Tabel 7, model VARIMA terbaik yang diperoleh adalah VARIMA(5, 1, 1) karena memiliki nilai AIC terkecil, yaitu -1,068289.

### 3.5. Uji Diagnosi Residual

Setelah model VARIMA terbaik diperoleh, dilakukan uji diagnostik residual menggunakan uji Ljung–Box pada pers. (6). Uji Ljung–Box dilakukan untuk memastikan bahwa residual tidak mengandung autokorelasi. Residual yang memenuhi asumsi *white noise* menunjukkan bahwa model telah mampu menangkap pola utama dalam data secara memadai. Hasil uji Ljung–Box disajikan pada Tabel 8.

**Tabel 8.** Hasil uji Ljung–Box pada residual model VARIMA(5, 1, 1)

Parameter cuaca	<i>P-value</i>
Suhu udara	0,9604
Kelembapan udara	0,8527
Kecepatan angin	0,3892


Berdasarkan Tabel 8, nilai *p-value* untuk suhu udara, kelembapan udara, dan kecepatan angin masing-masing sebesar 0,9604, 0,8527, dan 0,3892. Seluruh nilai tersebut lebih besar

dari 0,05, sehingga residual model dapat dinyatakan bersifat *white noise*. Hasil ini menunjukkan bahwa asumsi residual telah terpenuhi dan model VARIMA(5, 1, 1) layak digunakan pada tahap peramalan.

### 3.6. Model Hybrid VARIMA–ANN

Model *hybrid* VARIMA–ANN dibentuk dengan menggunakan residual dari model VARIMA terbaik sebagai masukan pada *Artificial Neural Network* (ANN). Pendekatan ini didasarkan pada asumsi bahwa meskipun model VARIMA telah mampu menjelaskan komponen linier dan hubungan multivariat antarparameter cuaca, masih terdapat pola nonlinier yang tersisa pada residual. Oleh karena itu, residual diperlakukan sebagai informasi tambahan yang masih mengandung struktur tertentu dan perlu dimodelkan lebih lanjut menggunakan ANN. Dengan pendekatan ini, model *hybrid* diharapkan tidak hanya mempertahankan kemampuan VARIMA dalam menangkap hubungan linier antarvariabel, tetapi juga meningkatkan akurasi melalui kemampuan ANN dalam mempelajari pola nonlinier yang lebih kompleks.

Arsitektur ANN dibangun menggunakan algoritma *backpropagation* yang terdiri atas tiga lapisan, yaitu *input layer*, *hidden layer*, dan *output layer*. *Input layer* dibentuk dari residual dengan mempertimbangkan *lag* signifikan berdasarkan MACF dan MPACF, yaitu *lag* 2, *lag* 5, dan *lag* 6. Berdasarkan proses tersebut, diperoleh 18 neuron pada lapisan input. Selanjutnya, *output layer* terdiri atas 3 neuron karena peramalan dilakukan terhadap tiga variabel cuaca. Adapun jumlah neuron pada *hidden layer* ditentukan menggunakan metode *trial and error* dari 1 hingga 10 neuron. Pemilihan arsitektur ini menunjukkan bahwa pembentukan model ANN tidak dilakukan secara sembarang, melainkan tetap mempertimbangkan informasi struktur residual yang diperoleh dari tahapan sebelumnya. Model terbaik diperoleh pada arsitektur ANN(18, 9, 3) dengan nilai RMSE pelatihan sebesar 6,125966. Nilai RMSE tersebut menunjukkan bahwa arsitektur terpilih memiliki kemampuan paling baik dalam meminimalkan galat pelatihan dibandingkan alternatif jumlah neuron *hidden* lainnya. Arsitektur model ANN terbaik disajikan pada Gambar 7.



Gambar 7. Arsitektur ANN(18, 9, 3) pada model *hybrid* VARIMA–ANN

Bobot yang menghubungkan setiap neuron pada *input layer*, *hidden layer*, dan *output layer* disajikan pada **Tabel 9** dan **Tabel 10**. **Tabel 9** menunjukkan bobot dari unit input ke unit *hidden*, sedangkan **Tabel 10** menunjukkan bobot dari unit *hidden* ke unit output.

**Tabel 9.** Bobot unit input ke unit *hidden*

Unit input ke- <i>i'</i>	Unit <i>hidden</i> ke- <i>j'</i>								
	1	2	3	4	5	6	7	8	9
<i>b</i>	-2,94	4,24	-7,26	3,26	-2,14	-1,14	1,23	3,01	-2,37
1	2,60	1,91	3,38	1,54	-0,91	5,61	-3,37	6,14	-2,04
2	5,52	1,23	-1,40	-0,06	-0,37	-2,40	1,89	-2,59	-0,40
3	-0,39	-1,01	1,17	2,34	-5,29	-2,45	-5,64	6,64	3,29
4	5,08	4,64	-2,54	2,54	0,89	2,34	-0,66	-0,46	-0,87
5	4,55	1,04	-8,13	-2,11	-0,93	-1,12	4,61	1,58	1,35
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
16	-6,64	7,27	-1,60	-0,79	6,06	-5,24	0,51	3,54	7,04
17	-0,17	0,62	-2,34	-5,66	-4,67	-3,15	-5,21	-0,05	0,00
18	1,41	0,08	-0,18	-2,47	-0,27	-1,12	-2,51	-1,72	-0,83

Berdasarkan **Tabel 9**, nilai *bias* untuk 9 unit *hidden* secara berturut-turut adalah -2,94, 4,24, -7,26, 3,26, -2,14, -1,14, 1,23, 3,01, dan -2,37. Variasi nilai bobot dan *bias* tersebut menunjukkan bahwa setiap neuron pada lapisan *hidden* memiliki kontribusi yang berbeda dalam mempelajari pola residual. Dengan kata lain, ANN membentuk representasi internal yang beragam untuk menangkap hubungan nonlinier dari data residual.

**Tabel 10.** Bobot unit *hidden* ke unit output

Unit <i>hidden</i> ke- <i>j'</i>	Unit output		
	1	2	3
<i>b</i>	0,86	-0,03	-2,90
1	0,10	1,71	0,86
2	-1,32	-2,00	-0,04
3	-0,25	-0,27	3,07
⋮	⋮	⋮	⋮
8	-1,14	2,52	2,11
9	1,66	-0,77	0,58

Sementara itu, **Tabel 10** menunjukkan bobot yang menghubungkan unit *hidden* dengan unit output, dengan nilai *bias* output masing-masing sebesar 0,86, -0,03, dan -2,90. Keberadaan bobot bernilai positif maupun negatif mengindikasikan bahwa hubungan antarneuron tidak bersifat seragam, melainkan saling menyesuaikan dalam proses pembelajaran untuk menghasilkan keluaran peramalan yang optimal.

Setelah model VARIMA dan ANN terbaik diperoleh, kedua model tersebut kemudian digabungkan untuk membentuk model *hybrid* VARIMA–ANN. Persamaan model VARIMA terbaik, yaitu VARIMA(5, 1, 1), dapat dituliskan pada **pers. (8)**.

$$\begin{bmatrix} SU_t \\ KU_t \\ KA_t \end{bmatrix} = \begin{bmatrix} 0,0068 \\ 0,0478 \\ -0,0076 \end{bmatrix} + \begin{bmatrix} -0,7159 & -0,4955 & -0,1272 \\ -0,1293 & -0,2319 & 0,5289 \\ 0,0421 & 0,1155 & 0,2962 \end{bmatrix} \begin{bmatrix} SU_{t-1} \\ KU_{t-1} \\ KA_{t-1} \end{bmatrix}$$

$$\begin{aligned}
 & + \begin{bmatrix} -0,2620 & -0,3031 & -0,0069 \\ -0,0210 & -0,2114 & 0,3046 \\ -0,2612 & -0,2491 & 0,2426 \end{bmatrix} \begin{bmatrix} SU_{t-2} \\ KU_{t-2} \\ KA_{t-2} \end{bmatrix} \\
 & + \begin{bmatrix} 0,0043 & -0,3156 & 0,0371 \\ -0,1838 & -0,2051 & -0,0502 \\ -0,0443 & -0,2796 & -0,0364 \end{bmatrix} \begin{bmatrix} SU_{t-3} \\ KU_{t-3} \\ KA_{t-3} \end{bmatrix} \\
 & + \begin{bmatrix} 0,0017 & -0,1452 & -0,0483 \\ 0,0442 & -0,1987 & -0,0330 \\ 0,3310 & 0,0168 & 0,0224 \end{bmatrix} \begin{bmatrix} SU_{t-4} \\ KU_{t-4} \\ KA_{t-4} \end{bmatrix} \\
 & + \begin{bmatrix} 0,1943 & -0,0309 & -0,0435 \\ 0,0998 & 0,0957 & -0,0080 \\ 0,3243 & 0,4426 & -0,1104 \end{bmatrix} \begin{bmatrix} SU_{t-5} \\ KU_{t-5} \\ KA_{t-5} \end{bmatrix} \\
 & + \begin{bmatrix} \alpha_{1,t} \\ \alpha_{2,t} \\ \alpha_{3,t} \end{bmatrix} - \begin{bmatrix} -0,4325 & 0,4577 & 0,1812 \\ 0,5281 & -0,2634 & -0,4702 \\ 0,5053 & 0,0736 & -0,6043 \end{bmatrix} \begin{bmatrix} \alpha_{1,t-1} \\ \alpha_{2,t-1} \\ \alpha_{3,t-1} \end{bmatrix}. \tag{8}
 \end{aligned}$$

Pers. (8) menunjukkan bahwa model VARIMA terbaik mampu menangkap hubungan dinamis antarparameter cuaca melalui komponen *autoregressive* hingga lag ke-5 serta komponen *moving average* orde 1. Dengan demikian, model ini telah merepresentasikan komponen linier utama dari data. Namun, karena residualnya masih dimodelkan lebih lanjut menggunakan ANN, dapat dipahami bahwa struktur linier saja belum cukup untuk menggambarkan keseluruhan perilaku data cuaca secara optimal.

Adapun persamaan umum model ANN terbaik dengan arsitektur ANN(18, 9, 3) dituliskan pada pers. (9).

$$\hat{y}_t = \sum_{j'=1}^9 w_{j'1} \left( \frac{1}{1 + e^{-v_{0j'}} + \sum_{i'=1}^{18} x_{i'} v_{i'j'}} \right) + w_{01}, \tag{9}$$

dengan:

- $\hat{y}_t$  : output jaringan atau hasil ramalan,
- $w_{j'1}$  : bobot yang menghubungkan neuron *hidden* ke neuron output,
- $v_{0j'}$  : bias pada unit *hidden*,
- $x_{i'}$  : input ke- $i'$ ,
- $v_{i'j'}$  : bobot dari unit input ke unit *hidden*,
- $w_{01}$  : bias pada unit *output*.

Pers. (9) menggambarkan bahwa ANN memanfaatkan kombinasi bobot, *bias*, dan fungsi aktivasi untuk memetakan residual ke dalam keluaran peramalan. Dalam konteks ini, ANN berperan sebagai pemodel komponen nonlinier yang belum dapat dijelaskan oleh VARIMA. Oleh karena itu, integrasi antara pers. (8) dan pers. (9) menghasilkan model *hybrid* yang menggabungkan keunggulan pendekatan statistik dan komputasional dalam satu kerangka pemodelan.

Akurasi model *hybrid* VARIMA–ANN dievaluasi menggunakan *Mean Absolute Percentage Error* (MAPE) pada pers. (7). Nilai MAPE menunjukkan rata-rata kesalahan prediksi dalam bentuk persentase. Hasil evaluasi MAPE model *hybrid* VARIMA(5, 1, 1)–ANN(18, 9, 3) disajikan pada Tabel 11.

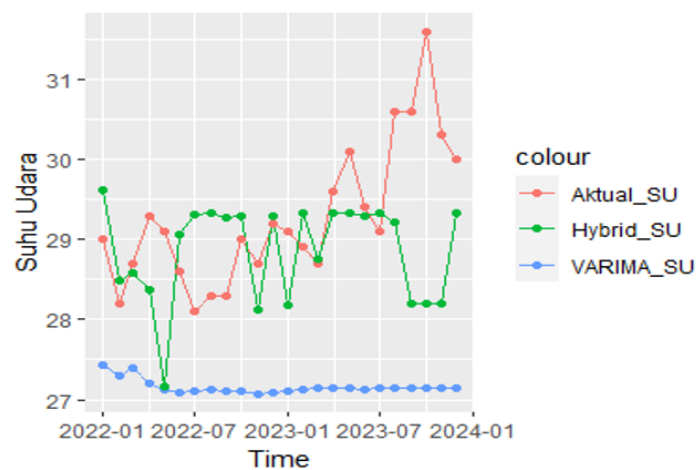
**Tabel 11.** Hasil MAPE model *hybrid* VARIMA–ANN

Variabel	MAPE	Akurasi
Suhu udara	1,32%	Sangat baik
Kelembapan udara	20,54%	Cukup baik
Kecepatan angin	21,96%	Cukup baik

Berdasarkan **Tabel 11**, model *hybrid* VARIMA–ANN memberikan akurasi terbaik pada variabel suhu udara dengan nilai MAPE sebesar 1,32%, yang termasuk kategori sangat baik. Hal ini menunjukkan bahwa pola suhu udara relatif lebih stabil sehingga lebih mudah dipelajari oleh model dibandingkan variabel lainnya. Sementara itu, nilai MAPE untuk kelembapan udara dan kecepatan angin masing-masing sebesar 20,54% dan 21,96%, yang berada pada kategori cukup baik. Perbedaan ini mengindikasikan bahwa karakteristik tiap parameter cuaca memengaruhi kinerja model dalam peramalan. Dengan demikian, model *hybrid* VARIMA–ANN tidak hanya unggul pada variabel dengan pola yang lebih teratur, tetapi juga tetap memberikan hasil prediksi yang memadai pada variabel yang lebih fluktuatif.

### 3.7. Hasil Peramalan

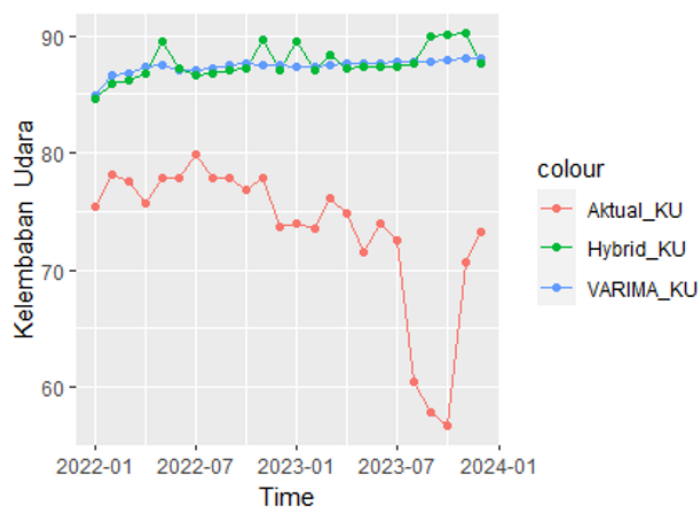
Grafik data aktual dan hasil peramalan parameter cuaca, yaitu suhu udara, kelembapan udara, dan kecepatan angin, menggunakan model VARIMA dan model *hybrid* VARIMA–ANN disajikan pada **Gambar 8–Gambar 10**. Penyajian grafik ini bertujuan memberikan gambaran visual kemampuan masing-masing model dalam mengikuti pola data aktual pada periode pengujian. Melalui perbandingan ini, kinerja model dinilai tidak hanya dari ukuran kuantitatif seperti MAPE, tetapi juga dari kemampuannya merepresentasikan kecenderungan pola, perubahan arah, dan fluktuasi tiap parameter cuaca.



**Gambar 8.** Perbandingan data aktual dan hasil peramalan suhu udara menggunakan model VARIMA dan *hybrid* VARIMA–ANN

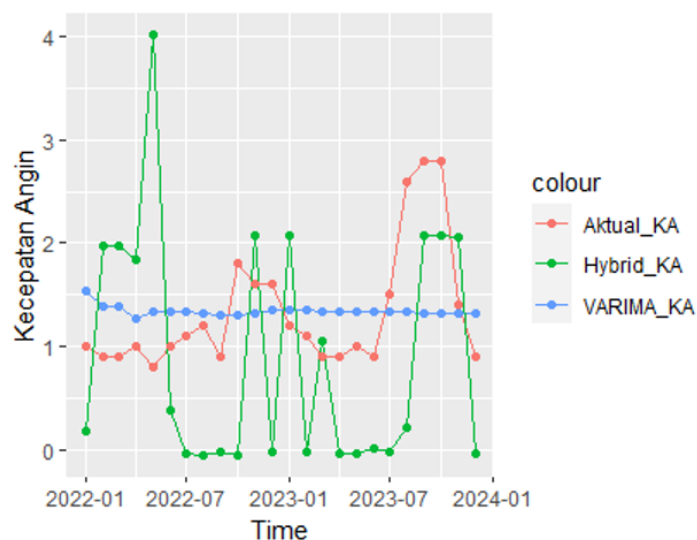
Berdasarkan **Gambar 8**, hasil peramalan suhu udara menggunakan model *hybrid* VARIMA–ANN terlihat lebih mendekati data aktual dibandingkan model VARIMA. Secara visual, kurva hasil peramalan model *hybrid* cenderung mengikuti arah pergerakan data aktual dengan lebih konsisten, baik ketika terjadi kenaikan maupun penurunan nilai suhu udara. Kedekatan pola ini menunjukkan bahwa penambahan ANN pada residual VARIMA mampu memperbaiki hasil peramalan, terutama dalam menangkap komponen nonlinier yang belum sepenuhnya dijelaskan oleh model linier. Temuan tersebut sejalan dengan nilai MAPE sebesar 1,32% pada

Tabel 11, yang menunjukkan bahwa akurasi peramalan untuk variabel suhu udara berada pada kategori sangat baik. Hasil ini juga mengindikasikan bahwa suhu udara memiliki pola yang relatif lebih stabil dan lebih mudah dipelajari oleh model dibandingkan variabel cuaca lainnya.



Gambar 9. Perbandingan data aktual dan hasil peramalan kelembapan udara menggunakan model VARIMA dan hybrid VARIMA–ANN

Selanjutnya, Gambar 9 menunjukkan hasil peramalan kelembapan udara. Secara visual, model hybrid VARIMA–ANN mampu mengikuti pola data aktual dengan cukup baik dan menghasilkan pola ramalan yang relatif stabil tanpa perubahan ekstrem. Dibandingkan model VARIMA, hasil ramalan model hybrid lebih adaptif dalam mengikuti perubahan level data, meskipun pada beberapa periode masih terdapat selisih antara nilai aktual dan ramalan. Hal ini menunjukkan adanya perbaikan kinerja, meskipun kemampuan model dalam menangkap dinamika kelembapan udara belum sebaik pada variabel suhu udara. Kondisi ini sejalan dengan nilai MAPE sebesar 20,54% pada Tabel 11, yang termasuk kategori cukup baik. Dengan demikian, kelembapan udara merupakan variabel dengan variasi yang lebih tinggi, sehingga memerlukan model yang mampu menangkap dinamika yang lebih kompleks.



Gambar 10. Perbandingan data aktual dan hasil peramalan kecepatan angin menggunakan model VARIMA dan hybrid VARIMA–ANN

Pada variabel kecepatan angin, **Gambar 10** menunjukkan bahwa hasil peramalan menggunakan model *hybrid* VARIMA–ANN cukup mendekati data aktual, meskipun masih terdapat fluktuasi yang tajam pada beberapa periode. Secara visual, model *hybrid* mampu mengikuti arah umum pola data, tetapi pada titik-titik tertentu belum sepenuhnya mampu merepresentasikan lonjakan atau penurunan yang terjadi secara mendadak. Hal ini menunjukkan bahwa kecepatan angin memiliki karakteristik yang lebih fluktuatif dan lebih sulit diprediksi dibandingkan suhu udara maupun kelembapan udara. Nilai MAPE kecepatan angin sebesar 21,96% pada **Tabel 11** menunjukkan bahwa akurasi peramalan untuk variabel ini juga berada pada kategori cukup baik. Meskipun demikian, hasil tersebut tetap menunjukkan bahwa model *hybrid* memberikan performa yang memadai dalam menangkap pola umum data kecepatan angin.

Secara keseluruhan, hasil pada **Gambar 8–Gambar 10** menunjukkan bahwa penerapan ANN pada residual VARIMA mampu meningkatkan kemampuan model dalam menangkap pola nonlinier, sehingga metode *hybrid* VARIMA–ANN memberikan hasil peramalan yang lebih baik dibandingkan model VARIMA. Perbedaan nilai MAPE pada setiap parameter juga menunjukkan bahwa tingkat akurasi peramalan sangat dipengaruhi oleh karakteristik masing-masing variabel cuaca. Variabel dengan pola yang lebih stabil, seperti suhu udara, cenderung menghasilkan akurasi yang lebih tinggi, sedangkan variabel dengan fluktuasi yang lebih besar, seperti kelembapan udara dan kecepatan angin, menghasilkan tingkat kesalahan peramalan yang relatif lebih besar.

#### 4. Kesimpulan

Berdasarkan hasil penelitian, model *hybrid* VARIMA–ANN terbaik yang diperoleh adalah VARIMA(5, 1, 1)–ANN(18, 9, 3) dengan algoritma *backpropagation*. Model *hybrid* tersebut dibentuk dengan menggunakan VARIMA untuk memodelkan pola linier multivariat pada parameter cuaca, sedangkan ANN digunakan untuk memodelkan pola nonlinier yang masih tersisa pada residual VARIMA. Berdasarkan hasil peramalan, diperoleh nilai *Mean Absolute Percentage Error* (MAPE) untuk masing-masing variabel, yaitu suhu udara sebesar 1,32%, kelembapan udara sebesar 20,54%, dan kecepatan angin sebesar 21,96%.

Hasil evaluasi menunjukkan bahwa tingkat kesalahan peramalan pada variabel suhu udara lebih rendah dibandingkan kelembapan udara dan kecepatan angin. Hal ini mengindikasikan bahwa kemampuan model dalam menghasilkan peramalan dipengaruhi oleh karakteristik masing-masing variabel, di mana suhu udara cenderung memiliki pola yang lebih stabil, sedangkan kelembapan udara dan kecepatan angin memiliki fluktuasi yang lebih tinggi.

Meskipun model *hybrid* mampu menghasilkan peramalan yang cukup baik, penelitian ini belum membandingkan performa model tersebut secara langsung dengan model tunggal VARIMA maupun ANN, sehingga keunggulan model *hybrid* belum dapat dinyatakan secara mutlak. Selain itu, keterbatasan penelitian ini terletak pada pemilihan struktur ANN dan parameter pelatihan yang masih bergantung pada metode *trial and error*, serta penggunaan ukuran evaluasi MAPE yang belum didukung oleh ukuran galat lainnya. Dengan demikian, penelitian selanjutnya perlu mempertimbangkan perbandingan langsung dengan model pembanding, seperti VARIMA dan ANN tunggal, serta pengembangan model *hybrid* lain, misalnya VARIMA–RNN atau VARIMA–LSTM. Selain itu, penggunaan algoritma pelatihan ANN yang lebih adaptif, seperti *adaptive learning rate* atau *Levenberg–Marquardt*, dapat dipertimbangkan untuk meningkatkan akurasi peramalan, khususnya pada variabel yang memiliki fluktuasi tinggi.

**Kontribusi Penulis.** Nur Anggraini T. Ali: Analisis formal, analisis data, administrasi, metodologi, perangkat lunak, kurasi data, dan penulisan–persiapan draf asli. Djihad Wungguli: Konseptualisasi, penulisan–tinjauan dan penyuntingan. Isran K. Hasan: Investigasi, supervisi, validasi.

**Ucapan Terima Kasih.** Penulis mengucapkan terima kasih kepada semua pihak yang telah berkontribusi dalam penelitian ini dan dalam penyusunan paper ini. Kami juga ucapkan terima kasih kepada editor dan reviewer atas masukan serta dukungannya dalam meningkatkan kualitas paper ini.

**Pembiayaan.** Penelitian ini tidak menerima pendanaan eksternal.

**Konflik Kepentingan.** Para penulis menyatakan tidak ada konflik kepentingan yang terkait dengan artikel ini.

**Ketersediaan Data.** Tidak tersedia.

## Referensi

- [1] T. Klein et al., “Interactions of Physical, Chemical, and Biological Weather Calling for an Integrated Approach to Assessment, Forecasting, and Communication of Air Quality,” *Ambio*, vol. 41, no. 8, pp. 851–864, 2012, doi: [10.1007/s13280-012-0288-z](https://doi.org/10.1007/s13280-012-0288-z).
- [2] I. Sofiati et al., “Performance of weather research forecasting model for seasonal prediction of precipitation over Indonesian maritime continent,” *Kuwait J. Sci.*, vol. 52, no. 1, p. 100293, 2025, doi: [10.1016/j.kjs.2024.100293](https://doi.org/10.1016/j.kjs.2024.100293).
- [3] A. Kurniadi, E. Weller, J. Salmond, and E. Aldrian, “Future projections of extreme rainfall events in Indonesia,” *Int. J. Climatol.*, vol. 44, no. 1, pp. 160–182, 2024, doi: [10.1002/joc.8321](https://doi.org/10.1002/joc.8321).
- [4] Z. A. Dwiyantri and C. Prianto, “Prediksi Cuaca Kota Jakarta Menggunakan Metode Random Forest,” *J. Tekno Insentif*, vol. 17, no. 2, pp. 127–137, 2023, doi: [10.36787/jti.v17i2.1136](https://doi.org/10.36787/jti.v17i2.1136).
- [5] S. Thakur and M. Pandey, “A Survey on Hybrid Models Used for Hydrological Time-Series Forecasting,” pp. 247–259, 2021.
- [6] L. Parviz, K. Rasouli, and A. Torabi Haghighi, “Improving Hybrid Models for Precipitation Forecasting by Combining Nonlinear Machine Learning Methods,” *Water Resour. Manag.*, vol. 37, no. 10, pp. 3833–3855, 2023, doi: [10.1007/s11269-023-03528-7](https://doi.org/10.1007/s11269-023-03528-7).
- [7] K. Zhang et al., “Research on a combined model based on linear and nonlinear features - A case study of wind speed forecasting,” *Renew. Energy*, vol. 130, pp. 814–830, 2019, doi: [10.1016/j.renene.2018.05.093](https://doi.org/10.1016/j.renene.2018.05.093).
- [8] S. Salehi and S. A. Akbar Salehi Neyshabouri, “A hybrid deep learning framework for improving short-term precipitation forecasts,” *Environ. Model. Softw.*, vol. 193, p. 106635, 2025, doi: [10.1016/j.envsoft.2025.106635](https://doi.org/10.1016/j.envsoft.2025.106635).
- [9] B. Mallick and J. K. Mantri, “A Hybrid KNN-MHWS-NNAR Univariate time Series Model for Anomaly Detection and Prediction of Relative Humidity Data,” *SN Comput. Sci.*, vol. 6, no. 7, p. 898, 2025, doi: [10.1007/s42979-025-04402-6](https://doi.org/10.1007/s42979-025-04402-6).
- [10] C.-J. Chen, C.-N. Huang, and S.-M. Yang, “Application of deep learning to multivariate aviation weather forecasting by long short-term memory,” *J. Intell. Fuzzy Syst.*, vol. 44, no. 3, pp. 4987–4997, 2023, doi: [10.3233/JIFS-223183](https://doi.org/10.3233/JIFS-223183).
- [11] F. Kurniawan and A. Triayudi, “Analysis of Interrelationships between Weather Parameters in North Jakarta and Central Jakarta Based on Predictions Using LSTM and GRU,” *SAGA J. Technol. Inf. Syst.*, vol. 2, no. 4, pp. 328–343, 2025, doi: [10.58905/saga.v2i4.398](https://doi.org/10.58905/saga.v2i4.398).
- [12] H. Yusuf, I. Djakaria, and R. Resmawan, “Penerapan Metode Double Moving Average Untuk Meramalkan Hasil Produksi Tanaman Padi di Provinsi Gorontalo,” *d’CARTESIAN*, vol. 9, no. 2, p. 92, 2020.
- [13] J. Jusmawati, M. Hadijati, and N. Fitriyani, “Penerapan Model Vector Autoregressive Integrate Moving Average dalam Peramalan Laju Inflasi dan Suku Bunga di Indonesia,” *Eig. Math. J.*, pp. 73–82, 2020, doi: [10.29303/emj.v3i2.62](https://doi.org/10.29303/emj.v3i2.62).
- [14] H. Fitrianti, S. M. Belwawin, M. Riyana, and R. Amin, “Climate modeling using vector moving average autoregressive,” *IOP Conf. Ser. Earth Environ. Sci.*, vol. 343, no. 1, p. 012201, 2019, doi: [10.1088/1755-1315/343/1/012201](https://doi.org/10.1088/1755-1315/343/1/012201).
- [15] A. Rusyana, N. Tatsara, R. Balqis, and S. Rahmi, “Application of Clustering and VARIMA for Rainfa-

- Il Prediction,” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 796, no. 1, p. 012063, 2020, doi: [10.1088/1757-899X/796/1/012063](https://doi.org/10.1088/1757-899X/796/1/012063).
- [16] I. D. Putri and A. Oktaviarina, “Penerapan Vector Autoregressive Integrated Moving Average (VARIMA) Pada Prediksi Indeks Standar Pencemaran Udara,” *MATHunesa J. Ilm. Mat.*, vol. 12, no. 2, pp. 364–373, 2024, doi: [10.26740/mathunesa.v12n2.p364-373](https://doi.org/10.26740/mathunesa.v12n2.p364-373).
- [17] M. P. Ayudhiah, S. Bahri, and N. Fitriyani, “Peramalan Indeks Harga Konsumen Kota Mataram Menggunakan Vector Autoregressive Integrated Moving Average,” *Eig. Math. J.*, pp. 1–8, 2020, doi: [10.29303/emj.v3i1.61](https://doi.org/10.29303/emj.v3i1.61).
- [18] H. Meliyana, M. Hadijati, and L. Harsyiah, “Forecasting the Amount of Water Discharge Based on the VARIMA Model,” *J. Varian*, vol. 8, no. 2, pp. 125–138, 2025, doi: [10.30812/varian.v8i2.3278](https://doi.org/10.30812/varian.v8i2.3278).
- [19] G. F. Dias and G. Kapetanios, “Estimation and forecasting in vector autoregressive moving average models for rich datasets,” *J. Econom.*, vol. 202, no. 1, pp. 75–91, 2018, doi: [10.1016/j.jeconom.2017.06.022](https://doi.org/10.1016/j.jeconom.2017.06.022).
- [20] M. Simionescu, “The Use of Varma Models in Forecasting Macroeconomic Indicators,” *Econ. Sociol.*, vol. 6, no. 2, pp. 94–102, 2013, doi: [10.14254/2071-789X.2013/6-2/9](https://doi.org/10.14254/2071-789X.2013/6-2/9).
- [21] M. Khozin, Z. Abidin, and T. Chamidy, “Stock Price Prediction Using Backpropagation ANN: Case Study of ADMR (2023–2025),” *J. Inf. Syst. Informatics*, vol. 7, no. 4, pp. 3407–3433, 2025, doi: [10.63158/journalisi.v7i4.1347](https://doi.org/10.63158/journalisi.v7i4.1347).
- [22] Muhtadin Akbar, Carlos Guterres, and Ana de Araújo, “A Backpropagation-Based Artificial Neural Network Model for Predicting Pharmaceutical Demand,” *J. Ris. Ilmu Tek.*, vol. 3, no. 1, pp. 1–15, 2025, doi: [10.59976/jurit.v3i1.155](https://doi.org/10.59976/jurit.v3i1.155).
- [23] E. GNANDI, J. Sadefo Kamdem, and P. F. Manuel, “Hybrid VARIMA-Machine Learning Models for Multivariate Macroeconomic and Energy Forecasting,” 2026, doi: [10.2139/ssrn.6224219](https://doi.org/10.2139/ssrn.6224219).
- [24] R. E. Caraka, R. C. Chen, H. Yasin, S. Suhartono, Y. Lee, and B. Pardamean, “Hybrid Vector Autoregression Feedforward Neural Network with Genetic Algorithm Model for Forecasting Space-Time Pollution Data,” *Indones. J. Sci. Technol.*, vol. 6, no. 1, pp. 243–266, 2021, doi: [10.17509/ijost.v6i1.32732](https://doi.org/10.17509/ijost.v6i1.32732).
- [25] I. K. Hasan, R. Resmawan, and J. Ibrahim, “Perbandingan K-Nearest Neighbor dan Random Forest dengan Seleksi Fitur Information Gain untuk Klasifikasi Lama Studi Mahasiswa,” *Indonesian Journal of Applied Statistics*, vol. 5, no. 1, pp. 58–66, 2022, doi: [10.13057/ijas.v5i1.58056](https://doi.org/10.13057/ijas.v5i1.58056).
- [26] I. Fadliani, I. Purnamasari, and W. Wasono, “Peramalan dengan metode SARIMA pada data inflasi dan identifikasi tipe outlier (Studi Kasus: Data Inflasi Indonesia Tahun 2008–2014),” *Jurnal Statistika Universitas Muhammadiyah Semarang*, vol. 9, no. 2, pp. 109–116, 2021.
- [27] W. W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*, 2nd ed. Greg Tobin, 2006.
- [28] M. Apriliani et al., “Peramalan indeks harga saham global menggunakan VARIMA dan VARIMAX dengan variabel dummy sebagai variabel eksogen,” Ph.D. dissertation, Universitas Hasanuddin, Makassar, Indonesia, 2022.
- [29] A. Pertiwi, L. F. Dewi, T. Toharudin, and B. N. Ruchjana, “Penerapan model *vector autoregressive integrated moving average* (VARIMA) untuk prakiraan indeks harga saham gabungan dan kurs rupiah terhadap USD,” 2021.
- [30] S. A. Antaristi, Y. Yundari, and H. Perdana, “Penerapan model *vector autoregressive integrated moving average* pada data logging,” *Bimaster: Buletin Ilmiah Matematika, Statistika dan Terapannya*, vol. 12, no. 3, 2023.
- [31] S. Pratiwi, “Pengaruh harga pangan terhadap inflasi dengan metode *vector autoregressive integrated moving average*,” *Jurnal Riset Statistika*, pp. 87–96, 2023.
- [32] P. R. Hardani, A. Hoyyi, and Sudarno, “Peramalan laju inflasi, suku bunga Indonesia dan indeks harga saham gabungan menggunakan metode *vector autoregressive* (VAR),” *Jurnal Gaussian*, vol. 6, no. 1, pp. 101–110, 2017.