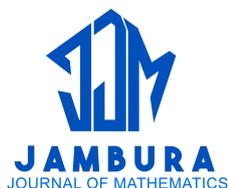


Efektivitas Metode Hibrida ARIMA-MLP untuk Peramalan Nilai Tukar Petani

Saffanah Nur Elvina Mulyawati dan Mujiati Dwi Kartikasari



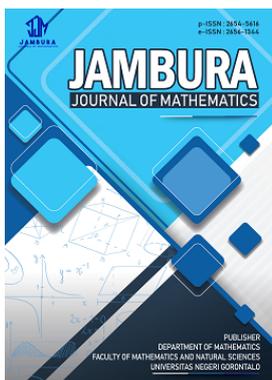
Volume 6, Issue 1, Pages 92–101, February 2024

Submit 4 Januari 2024, Direvisi 5 Februari 2024, Disetujui 7 Februari 2024

To Cite this Article : S. N. E. Mulyawati dan M. D. Kartikasari, "Efektivitas Metode Hibrida ARIMA-MLP untuk Peramalan Nilai Tukar Petani", *Jambura J. Math*, vol. 6, no. 1, pp. 92–101, 2024, <https://doi.org/10.37905/jjom.v6i1.23944>

© 2024 by author(s)

JOURNAL INFO • JAMBURA JOURNAL OF MATHEMATICS

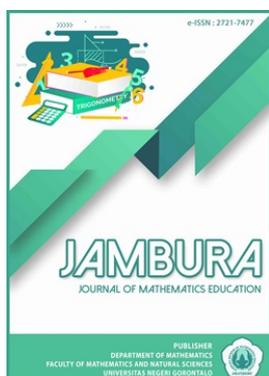


| | | | |
|--|----------------------|---|---|
| | Homepage | : | http://ejurnal.ung.ac.id/index.php/jjom/index |
| | Journal Abbreviation | : | Jambura J. Math. |
| | Frequency | : | Biannual (February and August) |
| | Publication Language | : | English (preferable), Indonesia |
| | DOI | : | https://doi.org/10.37905/jjom |
| | Online ISSN | : | 2656-1344 |
| | Editor-in-Chief | : | Hasan S. Panigoro |
| | Publisher | : | Department of Mathematics, Universitas Negeri Gorontalo |
| | Country | : | Indonesia |
| | OAI Address | : | http://ejurnal.ung.ac.id/index.php/jjom/oai |
| | Google Scholar ID | : | iWLjgaUAAAAJ |
| | Email | : | info.jjom@ung.ac.id |

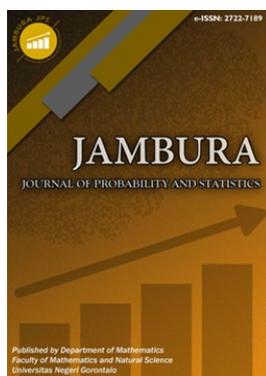
JAMBURA JOURNAL • FIND OUR OTHER JOURNALS



Jambura Journal of Biomathematics



Jambura Journal of Mathematics Education



Jambura Journal of Probability and Statistics



EULER : Jurnal Ilmiah Matematika, Sains, dan Teknologi



Efektivitas Metode Hibrida ARIMA-MLP untuk Peramalan Nilai Tukar Petani

Saffanah Nur Elvina Mulyawati^{1,*} dan Mujiati Dwi Kartikasari¹

¹Program Studi Statistika, Universitas Islam Indonesia, Indonesia

ARTICLE HISTORY

Submit 4 Januari 2024
Direvisi 5 Februari 2024
Disetujui 7 Februari 2024

KATA KUNCI

Peramalan
Hibrida ARIMA-MLP
ARIMA
Nilai Tukar Petani

KEYWORDS

Forecasting
Hybrid ARIMA-MLP
ARIMA
Farmer Exchange Rate

ABSTRAK. Sektor pertanian masih menjadi pilar penting perekonomian Indonesia dan memberikan kontribusi paling signifikan. Namun kondisi petani, terutama lansia, menunjukkan adanya keterbatasan fisik dan rendahnya pendapatan yang menyebabkan tingginya angka kemiskinan, ditambah dengan fluktuasi Nilai Tukar Petani (NTP) setiap tahunnya yang cenderung menurun di D.I. Yogyakarta, mengindikasikan kerugian akibat meningkatnya biaya produksi. Penelitian ini bertujuan untuk melihat efektivitas metode Hibrida Autoregressive Integrated Moving Average (ARIMA) – Multilayer Perceptron (MLP) dalam meramalkan NTP di D.I. Yogyakarta. Hal tersebut berdasarkan analisis perbandingan nilai akurasi peramalan dengan menggunakan evaluasi Mean Absolute Percentage Error (MAPE) ataupun melalui visualisasi grafik peramalan yang dihasilkan, pada metode ARIMA dan Hibrida ARIMA-MLP. Metode ARIMA dan MLP digabung (hibrida) dimaksudkan untuk mengatasi kompleksitas time series, di mana ARIMA mengantisipasi perubahan NTP dengan menangani pola linier, sementara MLP meningkatkan akurasi peramalan melalui kemampuannya menangani pola yang lebih kompleks (linier dan nonlinier). Dengan demikian, hal itu dapat memberikan informasi mengenai perkembangan kesejahteraan petani yang lebih akurat. Hasil menunjukkan bahwa metode Hibrida ARIMA-MLP jauh lebih baik dibandingkan dengan metode individu ARIMA, dengan model yang didapatkan adalah Hibrida ARIMA-MLP (12-5-10-2) dan nilai akurasi 99,993%.

ABSTRACT. The agricultural sector remains a crucial pillar of Indonesia's economy, making the most significant contribution. Still, the situation of farmers, primarily the elderly, indicates physical limitations and low income leading to high poverty levels, coupled with fluctuations in the Farmer Exchange Rate (FER) annually tending to decline in D.I. Yogyakarta, indicating losses due to increased production costs. This research aims to assess the effectiveness of the Hybrid Autoregressive Integrated Moving Average (ARIMA) – Multilayer Perceptron (MLP) method in forecasting NTP in D.I. Yogyakarta. This is based on the analysis of comparing the accuracy values of forecasts using Mean Absolute Percentage Error (MAPE) evaluation or through visualizing the forecast graphs generated between the ARIMA and Hybrid ARIMA-MLP methods. The combination (hybrid) of ARIMA and MLP methods addresses the complexity of time series, where ARIMA anticipates NTP changes by handling linear patterns. At the same time, MLP improves forecast accuracy by managing more complex patterns (both linear and nonlinear). Thus, it can provide more accurate information about the welfare development of farmers. The results show that the Hybrid ARIMA-MLP method is significantly better than the individual ARIMA method, with the obtained model being Hybrid ARIMA-MLP (12-5-10-2) and an accuracy of 99.993%.



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 JJB*: Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

1. Pendahuluan

Sektor pertanian di Indonesia, seiring dengan perkembangan zaman, masih memegang peranan sentral dalam pertumbuhan ekonomi. Data dari Badan Pusat Statistik (BPS) Triwulan I tahun 2023 mencatat kontribusi sektor pertanian terhadap Produk Domestik Bruto (PDB) sebesar 11,8 persen, menjadikannya salah satu sektor yang paling berperan [1]. Daerah Istimewa Yogyakarta (DIY), dengan mayoritas penduduknya yang bergantung pada pertanian, menjadi gambaran mikrokosmos akan pentingnya sektor ini. Meskipun demikian, realitas petani di Indonesia, terutama yang mayoritas merupakan lansia, menunjukkan gambaran

prihatin dengan adanya keterbatasan fisik dan pendapatan yang terbatas, menyebabkan tingkat kemiskinan yang tinggi.

Fakta terbaru dari Profil Kemiskinan di Indonesia Maret 2023, yang dirilis oleh BPS, menunjukkan tingginya tingkat kemiskinan petani di DIY, sekitar 11,04 persen atau 448.470 penduduknya hidup di bawah garis kemiskinan [2], membuat hal ini perlu dicari solusinya. Situasi ini secara signifikan dipengaruhi oleh fluktuasi Nilai Tukar Petani (NTP), yang menjadi indikator penting dalam menilai tingkat kesejahteraan petani [3]. NTP dihitung dari perbandingan antara indeks harga yang diterima petani (It) dan indeks harga yang dibayarkan oleh petani (Ib). Apabila nilai NTP lebih dari 100, petani dianggap memperoleh keuntungan; sebaliknya, nilai di bawah 100 menunjukkan kerugian akibat pen-

*Penulis Korespondensi.

dapatan yang menurun dan pengeluaran yang meningkat. Kemudian, apabila nilai NTP sama dengan 100, petani tidak mengalami kerugian atau keuntungan karena pendapatan seimbang dengan pengeluaran [4]. Fluktuasi NTP di DIY, yang menurun setiap tahunnya dari Januari 2015 hingga Desember 2022, menunjukkan adanya kerugian bagi petani karena biaya produksi yang meningkat melebihi pendapatan.

Menghadapi permasalahan kompleks ini, analisis peramalan dapat menjadi instrumen penting untuk dapat membantu para pemangku kepentingan dalam merumuskan strategi yang lebih efektif. Dengan menggunakan metode peramalan yang tepat, maka dapat memperoleh informasi yang mendalam sehingga masalah-masalah tersebut dapat diatasi secara bijak. Salah satu metode alternatif yang lebih efektif dalam peramalan adalah dengan menggabungkan model linier dan nonlinier, atau sering disebut sebagai model hibrida [5]. Ada tiga alasan utama penggunaan metode tersebut. Pertama, sulitnya menerapkan model linier dan nonlinier secara terpisah pada kasus *time series* tertentu. Kedua, dalam kenyataannya, *time series* jarang hanya mengandung pola linier atau nonlinier saja, melainkan seringkali mengandung keduanya. Ketiga, beberapa literatur peramalan menyatakan bahwa tidak ada satu model tunggal yang dapat bekerja secara optimal pada setiap situasi [6]. Pada penelitian ini, metode Hibrida ARIMA-MLP yang menjadi fokus utamanya. Hal tersebut dikarenakan, keunggulan model linier ARIMA dalam mengatasi karakteristik *time series* seperti *trend*, musiman, dan fluktuasi acak diharapkan dapat memberikan dasar yang kuat dalam mengantisipasi perubahan NTP. Sementara itu, kemampuan MLP yang termasuk model Jaringan Syaraf Tiruan (*Neural Network* atau disingkat NN), mampu menangani pola yang lebih kompleks (linier dan nonlinier) sehingga diharapkan dapat meningkatkan akurasi peramalan [7].

Terdapat dua penelitian yang melakukan peramalan NTP dengan menggunakan metode ARIMA, dapat dilihat pada [6, 7]. Hasil kedua penelitian tersebut menyatakan bahwasanya metode ARIMA memiliki tingkat akurasi yang sangat baik. Kemudian, dua penelitian lainnya yang melakukan peramalan NTP dengan menggunakan Jaringan Syaraf Tiruan, dapat dilihat pada [8, 9]. Kedua penelitian tersebut menyimpulkan bahwa tingkat akurasi yang dihasilkan jauh lebih baik. Sementara itu, beberapa penelitian lainnya yang melakukan peramalan dengan menggunakan metode hibrida, dapat dilihat pada [4, 10–14]. Hasil penelitian-penelitian tersebut, memberikan bukti keberhasilan model hibrida menunjukkan hasil positif yang akurasinya sangat baik, di mana model hibrida lebih unggul dibandingkan dengan model individu.

Berbeda dengan penelitian-penelitian sebelumnya yang berfokus pada aspek tertentu seperti penggunaan metode ARIMA individu [8, 9], Jaringan Syaraf Tiruan [10, 11], serta metode hibrida lainnya [12–16]. Adapun untuk objek yang digunakan berbeda-beda, seperti ada yang menangani NTP [6, 8–11], stok obat [14], harga minyak mentah [16], dan berbagai kasus lainnya. Adapun, penelitian ini difokuskan pada penerapan metode Hibrida ARIMA-MLP dengan pendekatan yang lebih terintegrasi, yakni menggabungkan metode linier (ARIMA) dan nonlinier (MLP) untuk mengoptimalkan peramalan NTP dalam mengatasi pola kompleks pada data *time series*. Maka dari itu, tujuan penelitian ini adalah untuk melihat efektivitas metode Hibrida ARIMA-MLP dalam meramalkan NTP di D.I. Yogyakarta. Melalui analisis per-

bandingan nilai akurasi peramalan menggunakan evaluasi MAPE ataupun dengan melihat visualisasi grafik peramalan yang dihasilkan, berdasarkan pada metode ARIMA dan Hibrida ARIMA-MLP. Salah satu alasan digunakan metode hibrida pada peramalan ialah tidak ada satu model tunggal yang dapat bekerja secara optimal pada setiap situasi [6]. Oleh karena itu, alternatifnya dapat dengan menggunakan metode hibrida. Efektivitas metode ini dengan membandingkannya pada metode ARIMA konvensional, penelitian memiliki dampak potensial yang besar, yakni memberikan kontribusi berharga terhadap kemajuan metodologi peramalan, meningkatkan akurasi prediksi, dan secara langsung relevan untuk pengambilan keputusan ekonomi dan perencanaan ke depan.

2. Metode

2.1. Sumber Data

Data pada penelitian ini diperoleh secara sekunder, yakni dari Badan Pusat Statistik (BPS) D.I. Yogyakarta [4]. Data tersebut ialah data Nilai Tukar Petani (NTP) selama periode Januari 2015 hingga Agustus 2023.

2.2. Variabel Penelitian

Variabel yang digunakan adalah Nilai Tukar Petani yang merupakan data *time series* periode bulanan di D.I. Yogyakarta. Adapun simbol untuk NTP periode bulanan yaitu Y_t , dengan Y merupakan NTP dan t merupakan indeks waktu.

2.3. Tahapan Analisis

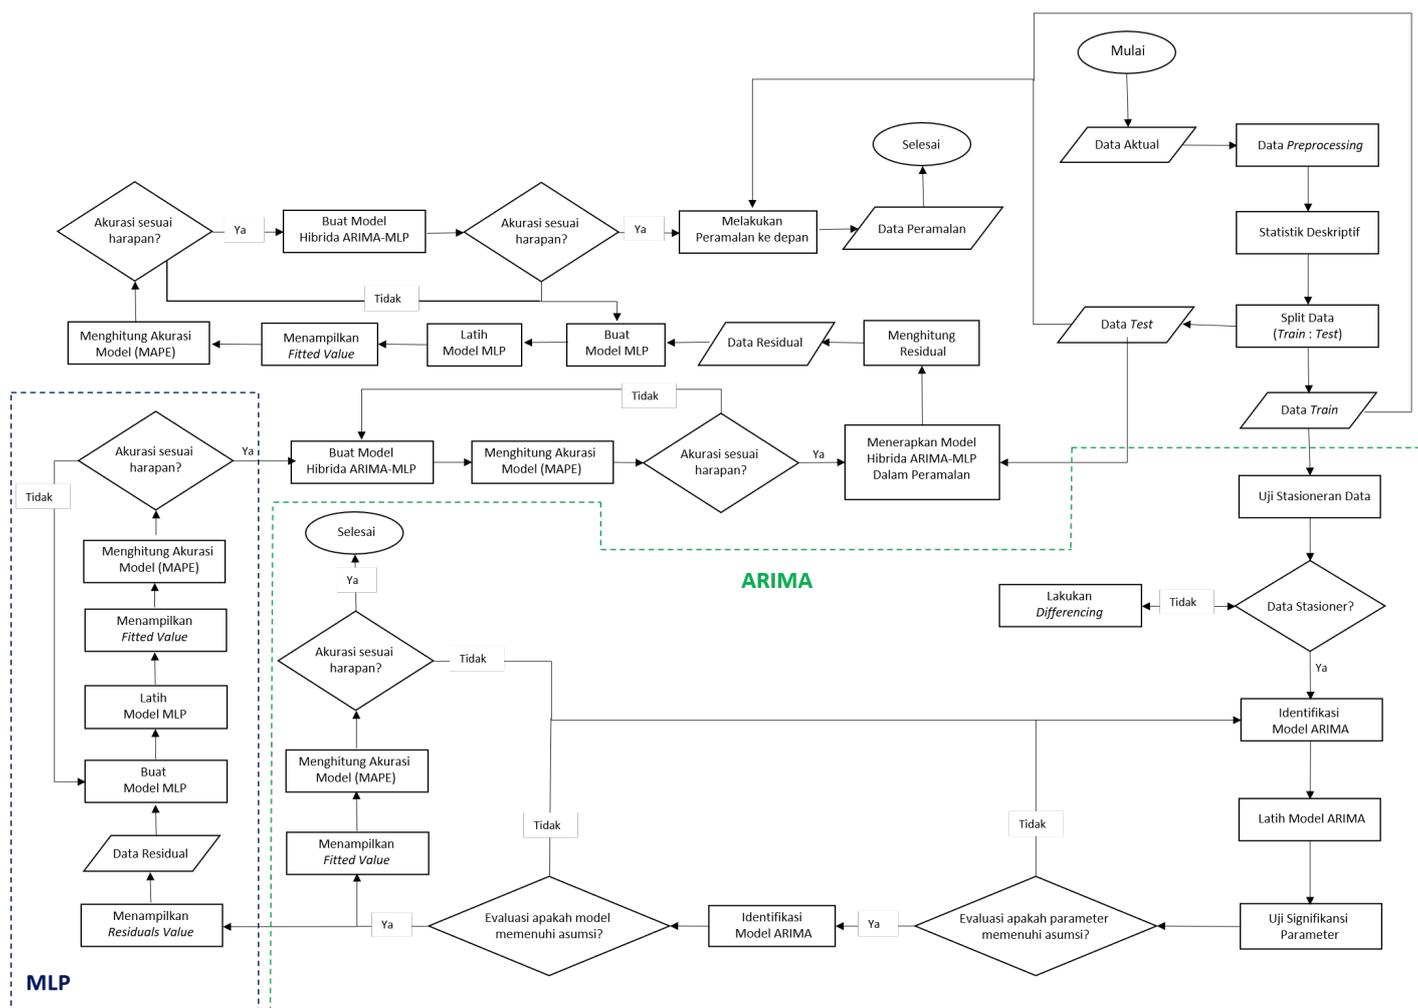
Metode analisis yang digunakan terdiri atas dua, yaitu Hibrida ARIMA-MLP dan ARIMA. Hal ini bertujuan sebagai pembandingan diantara kedua metode tersebut, yang kemudian akan dipilih metode mana yang terbaik. Selanjutnya, penelitian ini menggunakan bantuan *software* R-Studio untuk melakukan analisis.

2.3.1. Analisis Hibrida ARIMA-MLP

Pertama, melakukan *input data* dan *preprocessing data* (mengecek apakah ada *missing value* dan *outlier*). Kemudian, analisis deskriptif untuk mengetahui secara umum bagaimana data yang dimiliki (dapat berupa visualisasi). Setelah itu, *split data* menjadi data *train* dan *test*.

Lalu, uji stasioner data untuk mengecek apakah data sudah stasioner atau belum. Stasioneritas data dapat diidentifikasi melalui visual dengan melihat *Autocorrelation Function Plot* (ACF) dan *Partial Autocorrelation Function Plot* (PACF) [17]. Identifikasi stasioneritas data juga dapat dilakukan dengan menggunakan metode *Augmented Dickey-Fuller* (ADF) [18]. Jika data belum stasioner, maka dilakukan diferensiasi pertama, tetapi apabila data sudah stasioner maka dapat dilanjutkan ke langkah berikutnya. Namun, apabila belum memenuhi asumsi (data harus stasioner) maka dapat dilakukan diferensiasi kembali.

Selanjutnya, identifikasi model ARIMA yaitu dengan menentukan order (p, d, q) [19]. Penentuan order dapat dengan melihat *plot* ACF (untuk order MA(q)) dan PACF (untuk order AR(p)), serta untuk order (d) mengartikan berapa diferensiasi yang telah dilakukan. Kemudian, melakukan uji signifikansi pada parameter model. Jika parameter sudah signifikan, maka dapat melakukan uji diagnostik untuk mengetahui apakah residual data sudah bersifat *white noise* atau belum. Memenuhi asumsi apabila residu-



Gambar 1. Tahapan analisis metode hibrida ARIMA-MLP

al sudah bersifat *white noise* atau residual tidak saling berkorelasi [19]. Setelah residual dinyatakan tidak terdapat autokorelasi, maka dapat dihitung akurasi (MAPE) dengan menggunakan data aktual *train* dan data *fitted* hasil pelatihan model ARIMA. Adapun nilai MAPE secara matematis dapat dihitung dengan mengacu pada [20] dan dinyatakan dalam persamaan (1):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{y}_t - y_t}{y_t} \right| \times 100\% \quad (1)$$

dengan

- n : jumlah data pengamatan
- t : indeks waktu
- y_t : data aktual ke- t
- \hat{y}_t : data prediksi ke- t .

Untuk menentukan nilai akurasi model dikatakan baik atau buruk, maka dapat dengan berpacu pada ketentuan dari Moreno *et al.* [21] yang menyatakan adanya empat kategorisasi, diantaranya dikatakan akurasi sangat baik jika nilai $MAPE < 10\%$, dikatakan baik jika berada pada $10\% < MAPE \leq 20\%$, dikatakan layak jika berada pada $20\% < MAPE \leq 50\%$, dan dikatakan buruk jika nilai $MAPE > 50\%$. Adapun model ARIMA [19] secara matematis dapat dituliskan pada persamaan (2):

$$\phi_p(B) (1 - B)^d Y_t = \theta_q(B) a_t \quad (2)$$

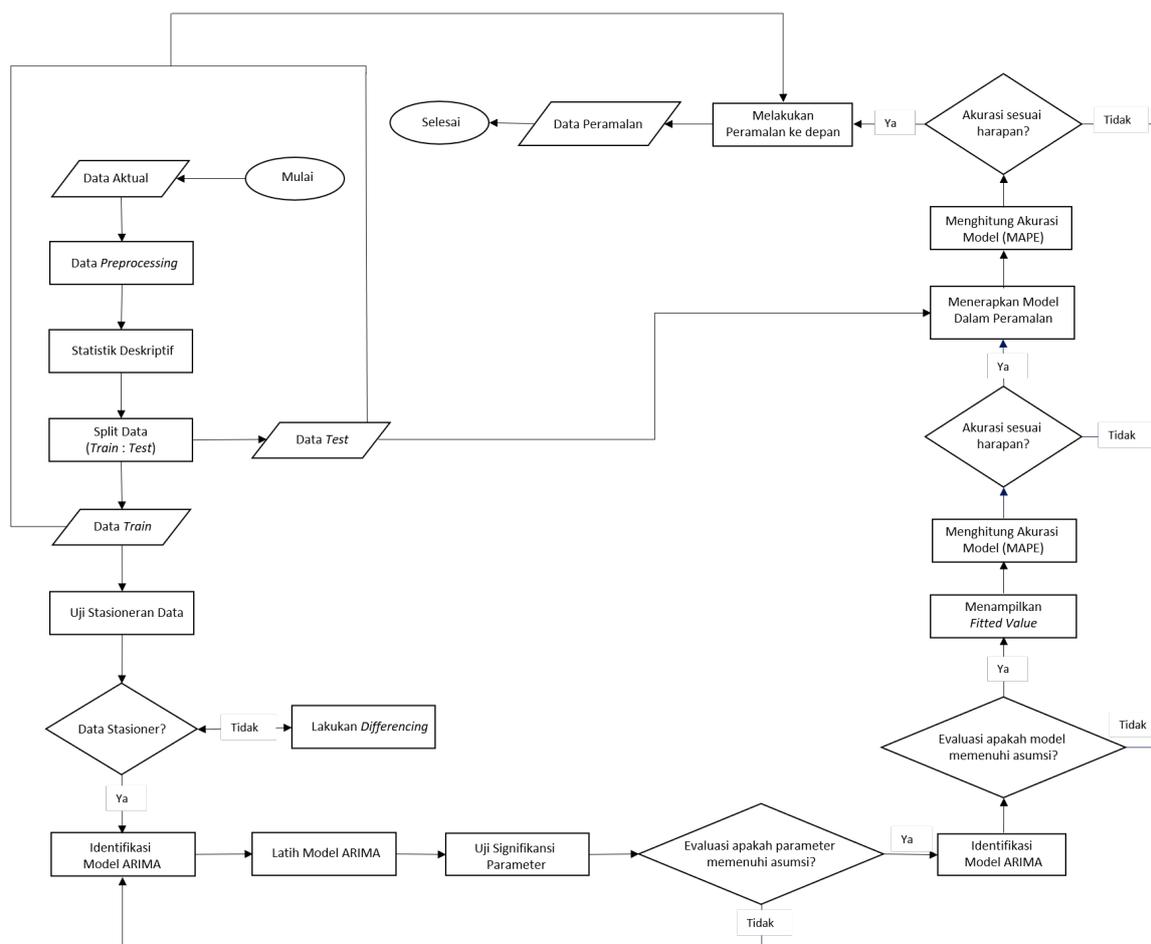
$$(1 - \phi_1(B) - \dots - \phi_p(B)^p) (1 - B) Y_t = (1 + \theta_1(B) + \dots + \theta_q(B)^q) a_t$$

dengan

- $\phi_p(B)$ = $1 - \phi_1(B) - \phi_2(B)^2 - \dots - \phi_p(B)^p$
- $\theta_q(B)$ = $1 - \theta_1(B) - \theta_2(B)^2 - \dots - \theta_p(B)^q$
- B : Operator *backshift* ($BY_t = Y_{t-1}$)
- $(1 - B)^d Y_t$: Runtun waktu stasioner dengan diferensiasi ke- d
- a_t : Residual ke- t , dimana $t = 1, 2, 3, \dots, n$.

Selanjutnya, residual dari hasil pemodelan dapat dijadikan sebagai *input* pada model MLP. Hal ini bertujuan untuk meramalkan nilai residual model ARIMA agar nilai akurasi menjadi lebih akurat. Persamaan matematis dari model MLP [22], diberikan pada persamaan (3):

$$\hat{y}_{t+1} = f^o \left[b^o + \sum_{j=1}^J \left[w_j^o f_j^h \left(b_j^h + \sum_{i=1}^I w_{ij}^h y_{i(t)} \right) \right] \right] \quad (3)$$



Gambar 2. Tahapan analisis metode ARIMA

dengan

- $y_i(t)$: input, di mana $(i = 1, 2, \dots, I)$
- \hat{y}_{t+1} : nilai estimasi variabel output
- w_{ij}^h : bobot input ke- i yang menuju neuron ke- j pada hidden layer, dimana $(j = 1, 2, \dots, J)$
- b_j^h : bias pada neuron ke- j pada hidden layer, dimana $(j = 1, 2, \dots, J)$
- f_j^h : fungsi aktivasi di neuron ke- j pada hidden layer, dimana $(j = 1, 2, \dots, J)$
- w_j^o : bobot dari neuron ke- j di hidden layer yang menuju neuron pada output layer
- b^o : bias pada neuron di output layer
- f^o : fungsi aktivasi pada neuron di output layer
- H : jumlah neuron pada hidden layer.

Setelah model dibuat dan dilatih maka dapat menghitung akurasi model MLP dengan menggunakan data residual ARIMA dan data fitted model MLP. Selanjutnya, setelah akurasi dinyatakan sesuai dengan harapan, maka dapat membuat pemodelan Hibrida ARIMA-MLP dengan menjumlahkan nilai fitted model ARIMA dan nilai fitted model MLP. Kemudian, dapat mengevaluasi model kembali dengan menghitung nilai MAPE. Adapun pemodelan Hibrida ARIMA-MLP dengan estimasi nilai linear autocorrelation (\hat{L}_t) dan estimasi nilai nonlinear (\hat{N}_t) mengacu pada [5] yang dapat dituliskan pada persamaan (4):

$$\hat{y}_t = \hat{L}_t + \hat{N}_t. \tag{4}$$

Setelah nilai akurasi model tersebut sudah dirasakan sesuai atau akurat, maka langkah selanjutnya dapat melakukan peramalan dengan menggunakan data test berdasarkan model ARIMA terbaik. Dilakukan peramalan pada data test dimaksudkan untuk memvalidasi akurasi apakah model yang telah dibuat pada data train mampu diterapkan pada data test atau tidak. Langkah yang dilakukan pun sama halnya seperti sebelumnya, yakni setelah melakukan peramalan tersebut maka dapat menentukan nilai residualnya. Lalu, dilanjutkan dengan peramalan nilai residualnya dengan metode MLP serta menghitung nilai akurasinya. Kemudian, buat kembali pemodelan hibridanya dan evaluasi dengan menghitung nilai MAPE berdasarkan data test.

Selanjutnya, untuk melakukan peramalan periode ke depan, maka dapat menggunakan data aktual secara keseluruhan. Langkahnya adalah setelah didapat nilai peramalan berdasarkan model ARIMA terbaik serta nilai residualnya. Maka berikutnya dapat melakukan peramalan residualnya dengan metode MLP. Lalu akhirnya dapat membuat model peramalan Hibrida ARIMA-MLP. Lebih lanjut, tahapan analisis Hibrida ARIMA-MLP direpresentasikan dalam bentuk flowchart pada Gambar 1.

2.3.2. Analisis ARIMA

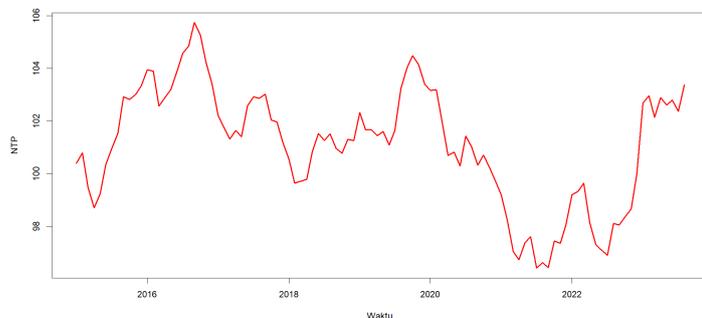
Adapun analisis dengan metode ARIMA dapat dilakukan dengan tahapan yang sama seperti pada metode Hibrida ARIMA-MLP. Hanya saja tidak melakukan tahap peramalan residual model ARIMA pada model MLP. Selanjutnya, tahapan analisis dengan

metode ARIMA direpresentasikan dalam bentuk *flowchart* pada Gambar 2.

3. Hasil dan Pembahasan

3.1. Statistika Deskriptif NTP

Perkembangan Nilai Tukar Petani (NTP) D.I. Yogyakarta selama periode Januari 2015 hingga Agustus 2023, dapat dilihat pada Gambar 3.



Gambar 3. Grafik perkembangan NTP D.I. Yogyakarta periode Januari 2015 – Agustus 2023

Gambar 3 menunjukkan bahwa tren Nilai Tukar Petani D.I. Yogyakarta mengalami fluktuatif selama periode Januari 2015 hingga Agustus 2023. Pada tahun 2015 hingga pertengahan 2016, terjadi peningkatan yang signifikan dalam nilai tukar, mencapai puncak tertinggi sebesar 105,75 pada bulan September 2016. Artinya, pada periode ini petani mengalami peningkatan pendapatan dan kesejahteraan. Namun, setelah 2016, terjadi penurunan bertahap hingga pertengahan 2021, hal ini menciptakan tantangan ekonomi bagi para petani. Pada tahun 2020, terdapat penurunan yang signifikan, mencapai rata-rata terendah pada 100,24, karena adanya pandemi *Covid-19*. Meskipun menghadapi tantangan tersebut, terdapat tanda-tanda pemulihan pada pertengahan 2021 hingga Agustus 2023. Nilai tukar kembali naik dan mencapai 103,38 pada bulan Agustus 2023. Hal tersebut, dapat mencerminkan upaya pemulihan ekonomi dan perbaikan kondisi kesejahteraan para petani. Pada tahun 2022, terdapat fluktuasi yang cukup besar, dengan nilai tukar bergerak naik-turun. Hal ini menunjukkan tingkat ketidakpastian ekonomi yang meningkat selama tahun tersebut.

Secara keseluruhan, rata-rata selama periode Januari 2015 hingga Agustus 2023 adalah 107,07. Hal ini menggambarkan petani cenderung mendapat keuntungan dan mengisyaratkan kondisi ekonomi yang mendukung bagi sebagian besar petani. Lalu, selama periode tersebut memiliki nilai terkecil sebesar 96,42 (pada Juli 2021) dan nilai terbesar sebesar 105,75 (pada September 2016). Rentang nilai tersebut adalah 9,33 menggambarkan sejauh mana ketidakstabilan nilai tukar dapat mempengaruhi pendapatan petani. Ketidakstabilan ini dapat disebabkan oleh berbagai faktor, seperti kondisi cuaca, perubahan kebijakan pemerintah, ataupun dinamika pasar.

3.2. Split Data (Data Train dan Data Test)

Split data atau pembagian data dilakukan dengan tujuan untuk mengetahui bagaimana model dapat bekerja dengan baik. Data dibagi menjadi dua yaitu data *train* dan data *test*. Data *train* digunakan untuk melatih data dalam pembuatan model. Semen-

tara, data *test* digunakan untuk memvalidasi model yang telah dilatih oleh data *train* dan mengevaluasinya dengan melihat nilai akurasi. Pada penelitian ini, data *train* selama periode Januari 2015 – Desember 2020 dan data *test* selama periode Januari 2021 – Agustus 2023. Secara rinci pembagian data *train* dan data *test* disajikan pada Tabel 1.

Tabel 1. Proporsi *split data*

| Data Train | Data Test |
|------------|-----------|
| 69% | 31% |
| 72 | 32 |

3.3. Uji Stasioneritas Data

Salah satu syarat dalam pemodelan ARIMA yaitu data harus memenuhi kondisi stasioner dalam *varians* dan *mean*. Untuk data yang diuji stasioneritas yaitu menggunakan data *train*. Identifikasi uji ini dapat dengan melihat secara visual pada *plot ACF* dan *PACF*. Data dianggap belum stasioner jika *plot ACF* menurun secara perlahan dengan pola eksponensial [17]. Apabila *plot ACF* menurun hingga mendekati nol dengan cepat, terutama setelah *lag* kedua atau ketiga, maka data dianggap stasioner [18].

Pada penelitian ini, diperlukan melakukan *differencing* sebanyak sekali agar data menjadi stasioner. Berikut perbedaan *plot* sebelum dilakukan *differencing* satu kali dan setelah dilakukan *differencing* satu kali disajikan pada Gambar 4.

Berdasarkan Gambar 4 terlihat bahwa sebelum dilakukan *differencing*, data menurun secara perlahan dengan pola eksponensial dan setelah *lag* kedua data belum menurun mendekati nol dengan cepat. Dengan demikian, data tersebut tidak stasioner. Oleh karena itu, dilakukan *differencing* satu kali untuk membuat data menjadi stasioner. Hasilnya dapat dilihat pada *plot ACF* dan *PACF* yang setelah dilakukan *differencing*. Pada *plot ACF* tersebut ditunjukkan bahwa data cepat menurun mendekati nilai nol, sehingga dengan dilakukan *differencing* sebanyak satu kali maka data sudah dapat dikatakan stasioner.

Selain melihat secara visualisasi, identifikasi stasioneritas data juga dilakukan menggunakan metode uji ADF dengan ketentuan sebagai berikut:

1. Penentuan Hipotesis, yaitu

$$H_0 : \delta = 0 \text{ (datatidakstasioner)}$$

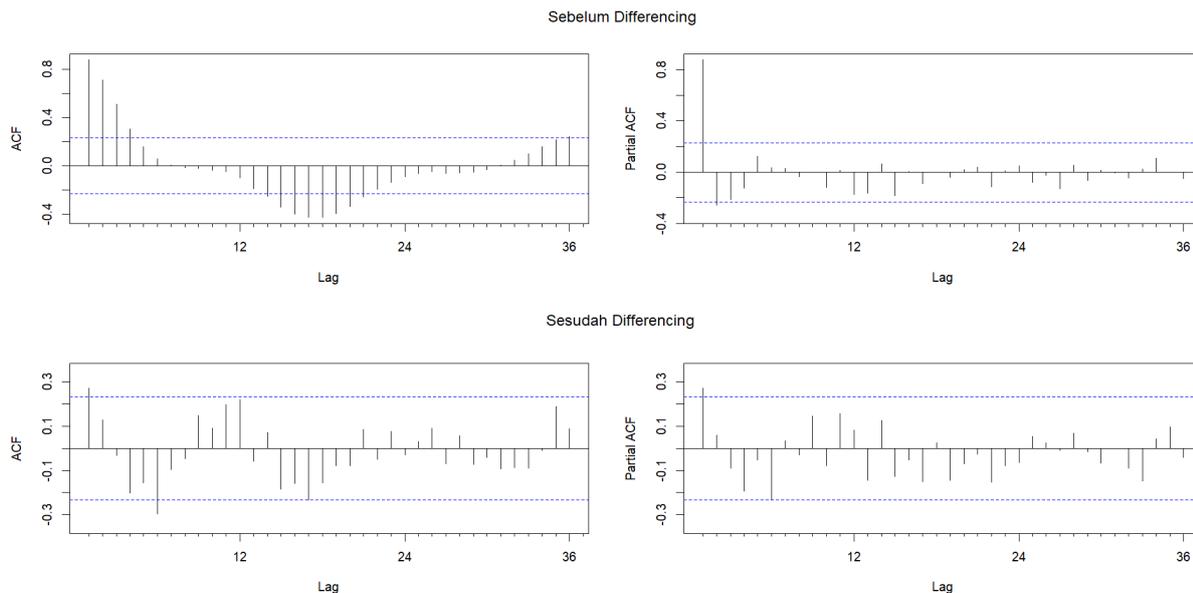
$$H_1 : \delta \neq 0 \text{ (datastasioner)}.$$

2. Tingkat Signifikansi $\alpha = 0,05$ (5%) dengan daerah kritis: Tolak H_0 jika $p\text{-value} < \alpha$.
3. Menentukan Statistik Uji
Hasil uji ADF sebelum dilakukan *differencing* satu kali dan setelah dilakukan *differencing* satu kali disajikan pada Tabel 2.

Tabel 2. Statistik hasil uji ADF sebelum dan setelah *differencing* (order 1)

| | Sebelum <i>Differencing</i> | Setelah <i>Differencing</i> |
|----------------------|-----------------------------|-----------------------------|
| <i>Dickey-Fuller</i> | -3,0296 | -4,2192 |
| <i>p-value</i> | 0,1561 | 0,01 |

4. Menentukan Keputusan
Keputusan hasil uji ADF sebelum dilakukan *differencing* satu



Gambar 4. Grafik ACF dan PACF (sebelum dan sesudah melakukan differencing satu kali)

kali dan setelah dilakukan differencing satu kali disajikan pada Tabel 3.

Tabel 3. Keputusan hasil uji ADF sebelum dan setelah differencing (order 1)

| | <i>p-value</i> | Tanda | <i>alpha</i> | Keputusan |
|----------------------|----------------|-------|--------------|-------------------|
| Sebelum Differencing | 0,1561 | ≥ | 0,05 | Gagal tolak H_0 |
| Setelah Differencing | 0,01 | < | 0,05 | Tolak H_0 |

5. Kesimpulan:

Dengan menggunakan tingkat kepercayaan sebesar 95% maka data yang sebelum dilakukan differencing satu kali ialah gagal tolak H_0 sehingga data NTP di D.I. Yogyakarta periode Januari 2015 – Desember 2020 adalah tidak stasioner. Sebaliknya, data yang telah dilakukan differencing satu kali menyatakan tolak H_0 artinya data tersebut sudah stasioner dan dengan kata lain, asumsi terpenuhi.

3.4. Pemodelan dan Peramalan ARIMA

Terdapat beberapa tahapan dalam pemodelan dan peramalan dengan metode ARIMA yaitu penentuan order ARIMA, melakukan estimasi parameter, pengecekan asumsi sekaligus menentukan model ARIMA yang terbaik, mengevaluasi model dengan nilai MAPE, dan melakukan peramalan di periode ke depan.

3.4.1. Penentuan Order ARIMA

Penentuan model ARIMA dapat dengan melihat plot ACF dan PACF yang telah dilakukan proses differencing order 1 (data sudah stasioner) pada Gambar 4. Berdasarkan plot ACF dan PACF pada Gambar 4, terlihat bahwa batang ACF keluar hingga lag ke-1 yang berarti nilai order MA yaitu $q = 1$. Kemudian, terdapat batang PACF keluar hingga lag ke-1 yang berarti nilai order AR yaitu $p = 1$. Dengan sebelumnya dilakukan differencing order 1 maka nilai $d = 1$. Oleh karena itu, diperoleh model $ARIMA(p, d, q) = ARIMA(1, 1, 1)$.

3.4.2. Estimasi Parameter Model ARIMA

Menurut hasil indikasi model ARIMA menggunakan ACF dan PACF pada Gambar 4, ditunjukkan bahwa order ARIMA yang terbentuk yaitu $ARIMA(1,1,1)$. Akan tetapi dengan model $ARIMA(1,1,1)$, diperoleh nilai signifikansi koefisien parameter yang tidak terpenuhi (karena $p-value \geq \alpha$ yakni 0,05). Hal ini dapat ditunjukkan pada Tabel 4.

Tabel 4. Signifikansi parameter ARIMA (1,1,1)

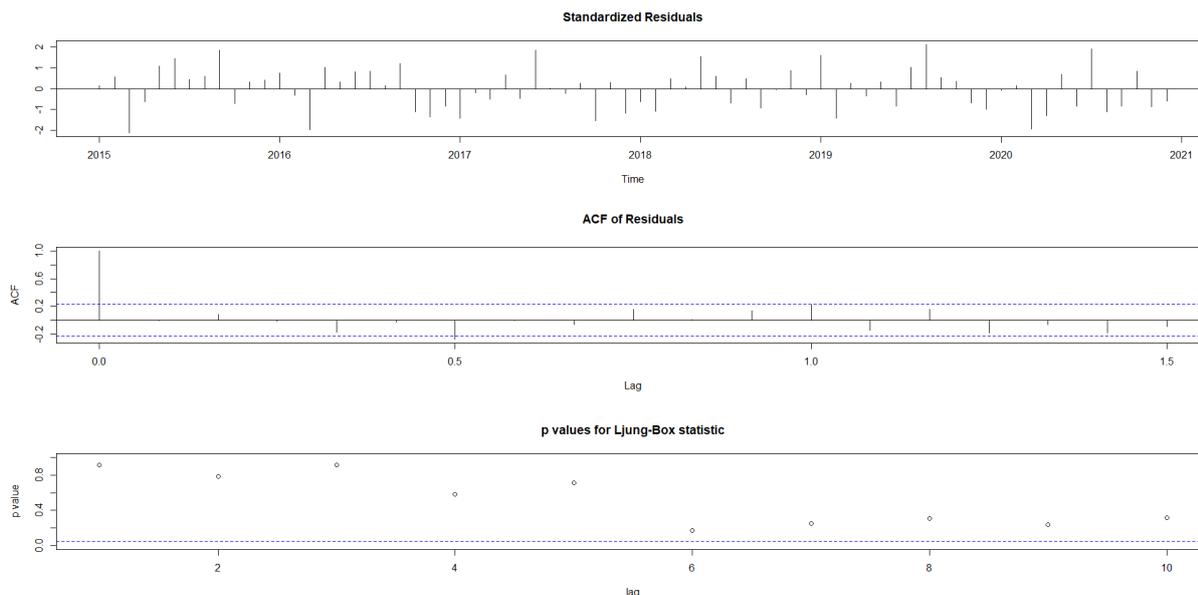
| | <i>p-value</i> | Tanda | <i>alpha</i> | Keputusan |
|-----|----------------|-------|--------------|-------------------|
| ar1 | 0,1935 | ≥ | 0,05 | Gagal tolak H_0 |
| ma1 | 0,7114 | ≥ | 0,05 | Gagal tolak H_0 |

Selanjutnya, dilakukan pembuatan model kedua yang memiliki order lebih rendah yakni $p = 1, d = 1, dan q = 0$ atau $ARIMA(p, d, q) = ARIMA(1, 1, 0)$. Perubahan yang dilakukan ada pada order q yang bernilai nol, mengindikasikan urutan dari komponen MA (Moving Average) dalam model ARIMA. Pada konteks ini, penggunaan $q = 0$ menunjukkan bahwa model ini tidak memperhitungkan kontribusi dari komponen MA. Penggunaan order yang lebih rendah dianggap sebagai pendekatan yang lebih sederhana sehingga mengurangi kompleksitas model. Kemudian, keputusan untuk memilih $q = 0$ karena cocok dalam memberikan model yang baik dalam merangkum pola data dengan tingkat signifikansi yang memadai, sebagaimana ditunjukkan pada Tabel 5. Berdasarkan model $ARIMA(1,1,0)$, ditunjukkan bahwa koefisien parameter dalam model tersebut signifikan (karena $p-value < \alpha$ yakni 0,05). Hasil signifikansi parameter model $ARIMA(1,1,0)$ selengkapnya disajikan pada Tabel 5.

Tabel 5. Signifikansi parameter ARIMA (1,1,1)

| | <i>p-value</i> | Tanda | <i>alpha</i> | Keputusan |
|-----|----------------|-------|--------------|-------------|
| ar1 | 0,0198 | < | 0,05 | Tolak H_0 |

Dengan demikian, didapatkan model terbaik saat ini adalah $ARIMA(1,1,0)$. Selanjutnya, perlu dilakukan uji asumsi pada



Gambar 5. Hasil uji diagnostik model ARIMA (1,1,0)

model untuk memvalidasi kembali keabsahan model tersebut.

3.4.3. Pengecekan Asumsi Model ARIMA

Pengecekan asumsi model yang dilakukan ialah uji diagnostik. Uji ini dapat dilakukan dengan menggunakan uji statistik *Ljung-Box* untuk mengevaluasi apakah ada autokorelasi dalam analisis model atau tidak [19]. Visualisasi hasil uji diagnostik ARIMA (1,1,0) disajikan pada Gambar 5.

Berdasarkan Gambar 5, dapat dilihat bahwa model ARIMA (1,1,0) memiliki sifat *white noise* (WN). Hal ini ditunjukkan pada tidak adanya batang yang melewati batas interval pada *lag* > 0, artinya tidak terdapat autokorelasi pada model ini. Selain itu, *p-value* pada *Ljung Box* juga di atas batas 5%, yang menandakan hipotesis nol residual tidak mengandung korelasi dan asumsi diterima. Dengan demikian berdasarkan uji asumsi diagnostik, maka dikatakan bahwa model terbaik penelitian ini adalah ARIMA (1,1,0).

3.4.4. Evaluasi Model ARIMA

Evaluasi model dalam penelitian ini adalah menggunakan nilai MAPE. Nilai tersebut bertujuan untuk menentukan bagaimana tingkat akurasi dari hasil peramalan model. Sebelum memperoleh model ARIMA terbaik dengan menggunakan data *train*, didapatkan nilai akurasi yang sangat baik. Kemudian, setelah diperoleh model ARIMA terbaik dengan menggunakan data *test*, didapatkan nilai akurasi yang sangat baik tetapi nilainya kurang dari sebelumnya. Hasil kedua nilai akurasi tersebut dapat dilihat pada Tabel 6.

Tabel 6. Nilai MAPE model ARIMA (1,1,0)

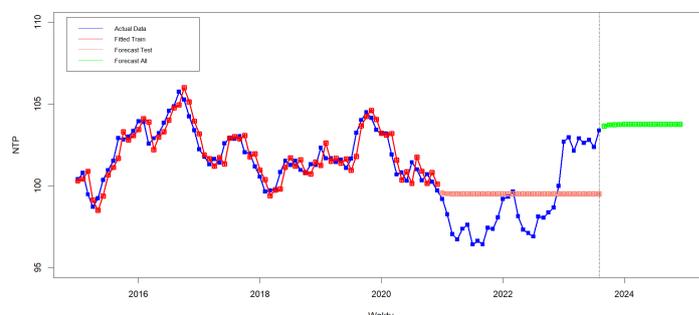
| | Data Train | Data Test |
|---------|------------|-----------|
| MAPE | 0,5377573 | 2,072447 |
| Akurasi | 99,46224 | 97,92755 |

Berdasarkan hasil data *test* pada Tabel 6, maka dapat diketahui bahwa model ARIMA (1,1,0) memiliki persentase tingkat aku-

rasi sebesar 97,93% dengan nilai MAPE 2,07% yang artinya sangat baik karena kurang dari 10%. Hal ini berdasarkan data *test* dikarenakan berpacu pada tujuan pembagian data, dimana data *test* digunakan sebagai evaluasi model secara keseluruhan (sebagai validasi dari proses *training*). Dengan demikian peramalan NTP dengan menggunakan model ARIMA menghasilkan akurasi yang sangat baik. Hasil ini sejalan dengan tingkat akurasi model yang ditunjukkan pada [6, 7].

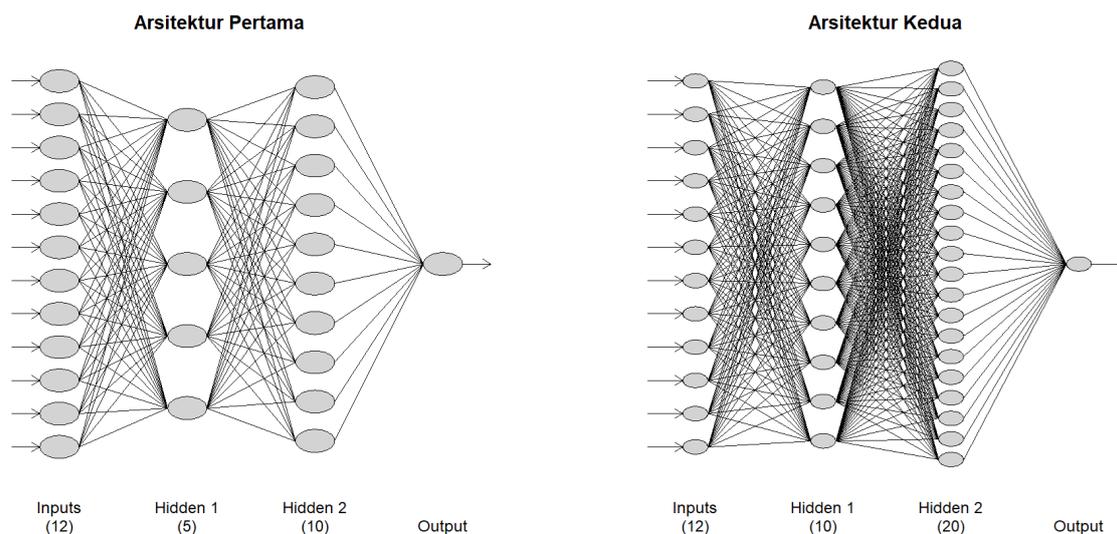
3.4.5. Peramalan Model ARIMA

Setelah dilakukan evaluasi model, maka tahap selanjutnya dilakukan peramalan untuk periode ke depan. Pada penelitian ini, dilakukan peramalan perkembangan NTP di D.I. Yogyakarta pada 16 periode ke depan, yakni pada September 2023 hingga Desember 2024. Hasil peramalan model ARIMA (1,1,0) yang disajikan pada Gambar 6 menunjukkan perkembangan NTP selama periode Januari 2015 hingga Agustus 2023 serta nilai peramalannya di 16 periode ke depan.



Gambar 6. Hasil peramalan model ARIMA (1,1,0)

Berdasarkan Gambar 6 terlihat bahwa terdapat empat garis yang berwarna. Warna biru menggambarkan data aktualnya sendiri, warna merah menggambarkan data *fitted* dari data *train*, warna *salmon* menggambarkan data *fitted* dari data *test*, dan warna hijau menggambarkan data peramalan dari model terse-



Gambar 7. Perbandingan kedua arsitektur MLP

but. Adanya ketidakcocokan antara garis berwarna *salmon* dengan warna biru, menandakan bahwa masih terdapat nilai yang belum akurat sehingga akan berdampak pada nilai peramalannya. Terlihat pada perkembangan di 16 periode ke depan yang cenderung stagnan. Oleh karena itu, untuk membandingkan metode mana yang lebih cocok, maka dilakukan perbandingan dengan metode lainnya yakni Hibrida ARIMA-MLP.

3.5. Pemodelan dan Peramalan Hibrida ARMA-MLP

Konsep hibrida yang dilakukan pada penelitian ini adalah hasil ramalan dari model ARIMA akan dijadikan komponen linier. Adapun residual dari model ARIMA dimodelkan dengan model *Multilayer Perceptron* (MLP) yang dijadikan komponen nonlinier. MLP adalah lapisan *perceptron* yang digabungkan dengan menambahkan lebih banyak *layer* dan *neuron* tiap *layer* [23]. Dengan banyaknya *layer*, model MLP dapat memahami struktur data yang lebih kompleks dan meningkatkan kemampuannya dalam meramalkan, dibandingkan dengan *layer* tunggal [24]. Arsitektur dari MLP terdiri atas tiga *layer*, yaitu *input layer* (lag observasi awal), *hidden layer* (fungsi transfer nonlinier untuk memproses informasi yang diterima dari *input layer*), dan *output layer* (memberikan hasil peramalan) [25].

Sebelum melakukan hibrida, terlebih dahulu dibuat pemodelan dan peramalan MLP untuk mengestimasi nilai residual yang didapatkan, sehingga akan menghasilkan nilai peramalan Hibrida ARIMA-MLP yang lebih akurat.

3.5.1. Pemodelan dan Peramalan MLP

Setelah didapatkan model ARIMA terbaik untuk data NTP periode bulanan di DIY, maka didapatkan residual dari model tersebut. Kemudian, nilai residual dari model ARIMA tersebut yang akan dijadikan sebagai *input*. Pada penelitian ini, terdapat 12 *neuron* pada *input layer* yang merupakan representatif dari data bulanan NTP. Untuk pemodelan MLP dibatasi, hal ini karena belum tentu dengan jumlah *neuron* yang banyak dapat diperoleh akurasi yang lebih baik [26]. Pembatasan tersebut maksudnya, peneliti menggunakan dua pilihan dalam menentukan struktur model MLP. Pertama dengan menggunakan dua *hidden layer*, dengan *la-*

yer pertama sebanyak lima *neuron* dan *layer* kedua sebanyak sepuluh *neuron*. Kemudian, yang kedua ialah dengan menggunakan dua *hidden layer*, dengan *layer* pertama sebanyak sepuluh *neuron* dan *layer* kedua sebanyak dua puluh *neuron*. Adanya dua *hidden layer* tersebut ialah untuk mengekstraksi pola kompleks dan hubungan nonlinier yang terdapat dalam nilai residual dari model ARIMA. Sementara itu, setiap *neuron* yang berda dalam *hidden layer* berfungsi sebagai unit pemrosesan informasi yang membantu menciptakan pemahaman yang lebih tinggi dari data masukan (*input*). Pembatasan jumlah *neuron* dan *hidden layer* juga perlu karena bertujuan untuk mencegah *overfitting* dan menjaga keseimbangan antara kompleksitas model dan kemampuan generalisasi pada data uji. Oleh karena itu, melalui dua pilihan struktur model MLP tersebut, diharapkan dapat menemukan konfigurasi yang optimal untuk meningkatkan kualitas prediksi. Selanjutnya, ditentukan arsitektur model mana yang terbaik dengan melihat nilai akurasi melalui nilai MAPE. Berdasarkan tahap *training* yang menggunakan data *train*, didapatkan arsitektur kedua pilihan tersebut yang ditampilkan pada Gambar 7, serta nilai akurasi dari kedua jenis pemodelan MLP yang disajikan pada Tabel 7.

Tabel 7. Nilai MAPE model MLP

| | MLP (12-5-10-1) | MLP (12-10-20-1) |
|---------|-----------------|------------------|
| MAPE | 4,367059 | 3,944713 |
| Akurasi | 95,63294 | 96,05529 |

Berdasarkan nilai MAPE pada Tabel 7, maka dapat dinyatakan bahwa peramalan data nilai residual sangat baik bagi kedua jenis arsitektur tersebut. Hal ini disebabkan karena nilai MAPE kurang dari 10%. Dengan demikian, kedua jenis arsitektur tersebut hingga pada tahap evaluasi model hibrida (*testing* Hibrida ARIMA-MLP).

3.5.2. Evaluasi Model Hibrida ARIMA-MLP

Evaluasi nilai akurasi Hibrida ARIMA-MLP berdasarkan penggunaan data *train* dapat dilihat pada Tabel 8. Adapun untuk evaluasi berdasarkan penggunaan data *test* dapat dilihat pada Tabel 9. Apabila ditinjau dari Tabel 8, maka diketahui bahwa kedua

jenis arsitektur tersebut memiliki nilai akurasi yang sangat baik, tetapi jika hanya dipilih satu saja untuk memilih jenis arsitektur MLP mana yang terbaik, maka akan terpilih jenis arsitektur yang pertama karena memiliki nilai MAPE terkecil.

Tabel 8. Nilai MAPE berdasarkan data *train*

| | Hibrida ARIMA-MLP (12-5-10-1) | Hibrida ARIMA-MLP (12-10-20-1) |
|---------|----------------------------------|-----------------------------------|
| MAPE | 0,009156531 | 0,006775828 |
| Akurasi | 99,99084 | 99,99322 |

Namun demikian, jika ditinjau secara keseluruhan maka akan berpaku pada penggunaan data *test*. Hal ini karena alasan yang sama seperti sebelumnya, yakni fokus pada tujuan pembagian data, dimana data *test* digunakan sebagai evaluasi model secara keseluruhan (sebagai validasi dari proses *training*).

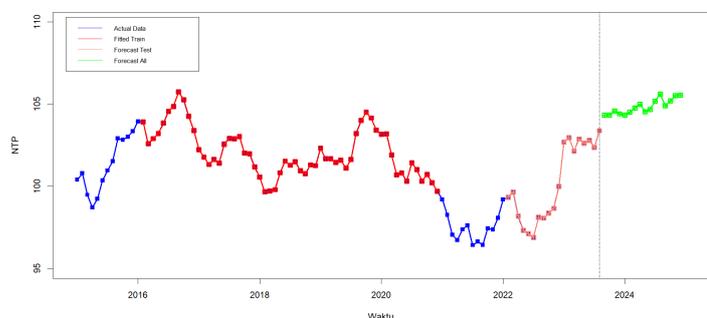
Tabel 9. Nilai MAPE berdasarkan data *test*

| | Hibrida ARIMA-MLP (12-5-10-1) | Hibrida ARIMA-MLP (12-10-20-1) |
|---------|----------------------------------|-----------------------------------|
| MAPE | 0,007242361 | 0,008379515 |
| Akurasi | 99,99276 | 99,99162 |

Berdasarkan Tabel 9 diketahui bahwa jenis arsitektur pertama yang memiliki nilai MAPE yang lebih kecil dibandingkan dengan yang kedua. Nilainya adalah 0,007% dengan persentase akurasi sebesar 99,993% yang artinya sangat baik. Dengan demikian, model Hibrida ARIMA-MLP (12-5-10-1) yang terpilih, dimana memiliki 12 neuron di *input layer*, 5 neuron di *hidden layer* pertama, 10 neuron di *hidden layer* kedua, dan 1 neuron di *output layer*.

3.5.3. Peramalan Model Hibrida ARIMA-MLP

Setelah dilakukan evaluasi model hibrida, maka tahap selanjutnya dapat dilakukan peramalan di periode ke depan. Dengan cara yang sama pada metode ARIMA, dilakukan peramalan perkembangan NTP di D.I. Yogyakarta pada 16 periode ke depan, yakni pada September 2023 hingga Desember 2024. Data yang disajikan pada Gambar 8 yang merupakan perkembangan NTP selama periode Januari 2015 hingga Agustus 2023 serta nilai peramalannya di 16 periode ke depan.



Gambar 8. Hasil peramalan model hibrida ARIMA-MLP (12-5-10-1)

Hasil peramalan model hibrida ARIMA-MLP berdasarkan Gambar 8, direpresentasikan dengan empat garis yang berwarna. Warna biru menggambarkan data aktualnya sendiri, warna merah menggambarkan data *fitted* dari data *train*, warna salmon

menggambarkan data *fitted* dari data *test*, dan warna hijau menggambarkan data peramalan dari model tersebut. Apabila ditinjau secara mendalam, terlihat bahwa adanya beberapa kecocokan antara garis berwarna salmon dengan warna biru. Hal ini menandakan bahwa nilai-nilai estimasi tersebut sudah akurat untuk merepresentatifkan data aktualnya. Terlihat pada 16 periode ke depan, perkembangan NTP cenderung fluktuatif, sehingga didapatkan nilai peramalannya pada Tabel 10.

Tabel 10. Data NTP D.I. Yogyakarta pada periode ke depan

| Tahun | Bulan | Estimasi |
|-------|-----------|----------|
| 2023 | September | 104,3229 |
| | Oktober | 104,3304 |
| | November | 104,5841 |
| | Desember | 104,4057 |
| 2024 | Januari | 104,3253 |
| | Februari | 104,5045 |
| | Maret | 104,7625 |
| | April | 104,9814 |
| | Mei | 104,5401 |
| | Juni | 104,6700 |
| | Juli | 105,1763 |
| | Agustus | 105,6138 |
| | September | 104,8897 |
| | Oktober | 105,1920 |
| | November | 105,5222 |
| | Desember | 105,5436 |

3.6. Perbandingan Nilai Akurasi Model ARIMA dan Hibrida ARIMA-MLP

Secara ringkas untuk mempermudah mengevaluasi metode mana yang lebih baik, antara metode ARIMA dengan Hibrida ARIMA-MLP maka diberikan hasil perbandingan nilai akurasi pada Tabel 11.

Tabel 11. Perbandingan Nilai Akurasi

| Metode | MAPE | Akurasi |
|-------------------------------|-------------|----------|
| ARIMA (1,1,0) | 2,072447 | 97,92755 |
| Hibrida ARIMA-MLP (12-5-10-1) | 0,007242361 | 99,99276 |

Berdasarkan Tabel 11, dapat diketahui bahwa metode yang terbaik adalah hibrida dengan model Hibrida ARIMA-MLP (12-5-10-1) yang memiliki nilai MAPE terkecil dan tingkat akurasi tertinggi yakni 99,993%.

Hal tersebut juga dapat dibuktikan dengan visualisasi hasil peramalan dari kedua metode tersebut, yang mana pada metode hibrida memiliki hasil yang jauh lebih baik dibandingkan dengan hasil metode individu-nya. Hal ini juga sejalan dengan nilai akurasi yang ditunjukkan pada [10–14].

4. Kesimpulan

Berdasarkan hasil analisis, dapat disimpulkan bahwa metode Hibrida ARIMA-MLP lebih efektif atau lebih baik dibandingkan dengan metode individu ARIMA. Hal ini ditunjukkan dengan nilai MAPE yang diperoleh, dimana model Hibrida ARIMA-MLP (12-5-10-1) memiliki nilai yang lebih kecil dibandingkan dengan model ARIMA (1,1,0), yaitu sebesar 0,007%. Hal ini juga menunjukkan bahwa model yang diperoleh memiliki nilai peramalan yang sa-

ngat baik. Adapun perkembangan NTP D.I. Yogyakarta selama 16 periode ke depan, yakni September 2023 hingga Desember 2024 mengalami tren yang fluktuatif meningkat dengan nilainya di atas 100. Hal ini mengindikasikan bahwa petani di wilayah D.I. Yogyakarta selama periode tersebut akan mengalami keuntungan. Namun, tidak menutup kemungkinan nilai tersebut akan berubah jika adanya suatu momen yang tak terduga, seperti pandemi global ataupun kestabilan ekonomi yang tidak pasti. Oleh karena itu, dengan melihat prediksi tren NTP, pemerintah dapat menerapkan kebijakan responsif, seperti program sosialisasi untuk petani, peningkatan alokasi dana bantuan finansial, dan dukungan pemasaran produk pertanian. Hal ini bertujuan agar pemangku kepentingan, terutama petani, dapat lebih siap dan mengoptimalkan keuntungan. Mereka dapat melakukan perencanaan waktu tanam dan panen dengan lebih efisien, mengurangi risiko kerugian, dan memilih jenis tanaman yang sesuai dengan perkiraan kondisi. Implementasi kebijakan ini diharapkan dapat meningkatkan hasil pertanian secara keseluruhan dan mengurangi potensi kerugian.

Kontribusi Penulis. Saffanah Nur Elvina Mulyawati: Konseptualisasi, metodologi, studi literatur, analisis, visualisasi, dan penulisan naskah. Mujiati Dwi Kartikasari: Konseptualisasi, metodologi, studi literatur, analisis, validasi, tinjauan penulisan, dan supervisi. Semua penulis telah membaca dan menyetujui versi manuskrip yang diterbitkan.

Ucapan Terima Kasih. Para penulis menyampaikan terima kasih kepada editor dan reviewer atas pembacaan yang cermat, kritik yang mendalam, dan rekomendasi yang praktis untuk meningkatkan kualitas tulisan ini.

Pembiayaan. Penelitian ini tidak menerima pembiayaan eksternal.

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

Referensi

- [1] BPS, "Pertumbuhan Ekonomi Indonesia Triwulan I-2023," in Berita Resmi Statistik, No. 34/05/2023, pp. 1–13. [Online]. Available: <https://www.bps.go.id/id/pressrelease/2023/05/05/1998/ekonomi-indonesia-triwulan-i-2023-tumbuh-5-03-persen-y-on-y-.html>
- [2] BPS, "Profil Kemiskinan di Indonesia Maret 2023," in Berita Resmi Statistik, No. 47/07/2023, pp. 1–14. [Online]. Available: <https://www.bps.go.id/id/pressrelease/2023/07/17/2016/profil-kemiskinan-di-indonesia-maret-2023.html>
- [3] BPS, Statistik Nilai Tukar Petani 2022. Jakarta: Badan Pusat Statistik, 2023.
- [4] BPS, "Nilai Tukar Petani (NTP)," 2023. [Online]. Available: <https://yogyakarta.bps.go.id/subject/22/nilai-tukar-petani>
- [5] G. P. Zhang, Time series forecasting using a hybrid ARIMA and neural network model. USA: Neurocomputing, 2003. doi: 10.1016/S0925-2312(01)00702-0.
- [6] I. K. Hasan and I. Djakaria, "Perbandingan Model Hybrid ARIMA-NN dan Hybrid ARIMA-GARCH untuk Peramalan Data Nilai Tukar Petani di Provinsi Gorontalo," *J. Stat. dan Apl.*, vol. 5, no. 2, pp. 155–165, 2021, doi: 10.21009/JSA.05204.
- [7] P. Young-Seuk and L. Sovan, "Artificial Neural Networks: Multilayer Perceptron for Ecological Modeling," in *Ecological Model Types, Elsevier*, vol. 28, pp. 123–140, 2016, doi: 10.1016/B978-0-444-63623-2.00007-4.
- [8] D. W. Yunita, "Peramalan Nilai Tukar Petani di Jawa Timur Menggunakan ARIMA BOX JENKINS," Institut Teknologi Sepuluh Nopember, 2018.
- [9] W. Istiqomah and M. Y. Darsyah, "Efektivitas Metode Arima dan Exponential Smoothing untuk Meramalkan Nilai Tukar Petani di Jawa Tengah," in *Prosiding Seminar Nasional Mahasiswa Unimus*, 2018, pp. 343–350.
- [10] T. W. Khusniyah and Sutikno, "Prediksi Nilai Tukar Petani Menggunakan Jaringan Syaraf Tiruan Backpropagation," *Sci. J. Informatics*, vol. 3, pp. 11–18, 2016, doi: 10.15294/sji.v3i1.4970.
- [11] E. Widada, "Prediksi Nilai Tukar Petani D.I.Yogyakarta Menggunakan JST dengan Algoritma Backpropagation," Universitas Teknologi Yogyakarta, 2018.
- [12] M. Khashei and Z. Hajirahimi, "Performance Evaluation of Series and Parallel Strategies for Financial Time Series Forecasting," *Financ. Innov.*, vol. 3, pp. 1–24, 2017, doi: 10.1186/s40854-017-0074-9.
- [13] D. S. de O. S. Júnior, J. F. L. de Oliveira, and P. S. G. de M. Neto, "An Intelligent Hybridization of ARIMA with Machine Learning Models for Time Series Forecasting," *Knowledge-Based Syst.*, vol. 175, pp. 72–86, 2019, doi: 10.1016/j.knsys.2019.03.011.
- [14] N. Tampati, Y. M. Pranoto, and Gunawan, "Prediksi Stok Obat Pada Total Life Clinic Menggunakan Model Kombinasi Artificial Neural Network dan ARIMA," *J. Tek. Inform. dan Sist. Inf.*, vol. 9, pp. 49–58, 2022, doi: 10.35957/jatisi.v9i1.1373.
- [15] E. Setyowati and R. C. Utama, "Implementation of hybrid ARIMA-neural network model: Total assets of Indonesia Sharia banking data," in *AIP Conference Proceedings*, 2023. doi: 10.1063/5.0154635.
- [16] D. A. Angraini, S. Wahyuningsih, and M. Siringoringo, "Peramalan Harga Minyak Mentah Indonesia Jenis Sepinggian Yakin Mix Menggunakan Model Hybrid ARIMA-NN," *J. Ris. Pembang.*, vol. 5, pp. 105–118, 2023, doi: 10.36087/jrp.v5i2.138.
- [17] S. Maslikha, N. Fitriyati, and Mahmudi, "Aplikasi Model GSTAR-I dengan Pendekatan Invers Matriks Autokovarians (IMAK) pada Prakiraan Curah hujan di Provinsi Banten," *J. LOGIK@*, pp. 73–85, 2017.
- [18] J. E. Hanke and D. W. Wichern, *Business Forecasting*, Eight Edition. New Jersey: Pearson Prentice Hall, 2005.
- [19] W. W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*, Second Edition. Pearson Prentice Hall, 2006.
- [20] A. de Myttenaere, B. Golden, L. B. Grand, and F. Rossi, "Using Mean Absolute Percentage Error for Regression Models," *23rd Eur. Symp. Artif. Neural Network, Comput. Intell. Mach. Learn.*, 2015, doi: 10.48550/arXiv.1506.04176.
- [21] J. J. M. Moreno, A. P. Pol, A. S. Abad, and B. C. Blasco, "Using the R-MAPE index as a resistant measure of forecast accuracy," *Psicothema*, vol. 25, pp. 500–506, 2013, doi: 10.7334/psicothema2013.23.
- [22] E. K. P. Chong and S. H. Zak, *An Introduction to Optimization*, Fourth Edition. John Wiley & Sons, Inc., Hoboken, New Jersey, 2013.
- [23] S. Sen, D. Sugiarto, and A. Rochman, "Prediksi Harga Beras Menggunakan Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM)," *Ultim. J. Tek. Inform.*, vol. 12, no. 1, pp. 35–41, 2020, doi: 10.31937/ti.v12i1.1572.
- [24] Y. Ardilla, "Metode Hibrida ARIMA Dan Multilayer Perceptron Untuk Peramalan Jangka Pendek Konsumsi Listrik Di Jawa Timur - Hybrid ARIMA And Multilayer Perceptron For Short Term Forecasting Of Electricity Consumption In East Java," Institut Teknologi Sepuluh Nopember, 2016. [Online]. Available: <http://repository.its.ac.id/id/eprint/72011>.
- [25] L. S. Dewi, "Prediksi Harga Saham Perusahaan Kelapa Sawit Menggunakan Pemodelan MLP Dan RBF," *Techno Nusa Mandiri*, vol. 11, no. 1, pp. 79–85, 2014.
- [26] P. Wibowo, S. Suryono, and V. Gunawan "Pengaruh Perbedaan Jumlah Hidden Layer dalam Jaringan Syaraf Tiruan Terhadap Prediksi Kebutuhan Captopril dan Paracetamol pada Rumah Sakit," *J. Media Aplikom*, vol. 11, no. 2, pp. 45–58, 2019, doi: 10.33488/2.ma.2019.2.207.