

Comparison of Sarima and Exponential Smoothing Methods in Forecasting Exchange Rates for Farmers in Central Java Province

Muhammad Naufal Annabil ^{1*}, Marcellinus Yosep Teguh Sulistyono ^{2*}

* Sistem Informasi, Universitas Dian Nuswantoro

112202206922@mhs.dinus.ac.id ¹, teguh.sulistyono@dsn.dinus.ac.id ²

Article Info

Article history:

Received 2025-09-30

Revised 2025-11-18

Accepted 2025-11-22

Keyword:

SARIMA,
Exponential Smoothing,
Farmer Exchange Rates,
Time Series Forecasting.

ABSTRACT

This study compares the performance of the SARIMA and Exponential Smoothing (Holt-Winters) models in forecasting the Farmer Exchange Rate (NTP) for Central Java Province from 2016 to 2025. The monthly statistical data used was obtained from the Central Java Provincial Statistics Agency. The models were evaluated using MAE (Mean Absolute Error) and RMSE (Root Mean Squared Error) on test data for the period January 2016 to September 2025, while forecasting was carried out from October 2025 to December 2027. The results show that the SARIMA (1,1,1) (1,1,1,12) model has an MAE of 6.94 and an RMSE of 7.88, indicating that the model can make accurate predictions with few errors. However, the Exponential Smoothing model has a lower MAE and RMSE, implying that this model is more accurate in forecasting long-term NTP. Both models show comparable seasonal trends, with Exponential Smoothing being more stable and sensitive to seasonal changes. This study also proposes the use of alternative forecasting approaches, such as ARIMAX, VAR, or machine learning to improve the accuracy of future forecasts. The results of this study can be used to develop agricultural policies that maintain food price stability, improve farmer welfare, and predict future inflation fluctuations.



This is an open access article under the [CC-BY-SA](#) license.

I. PENDAHULUAN

Nilai Tukar Petani (NTP) merupakan indikator utama yang bisa digunakan untuk mengukur tingkat kesejahteraan petani di Indonesia [1]. Rasio NTP diukur berdasarkan membandingkan indeks harga yang diterima petani (It) dengan indeks harga yang dibayar petani (Ib). Apabila NTP berada di atas 100, maka petani dianggap mengalami surplus karena harga yang diterima lebih tinggi dibandingkan pengeluaran. Sebaliknya, apabila rasio NTP berada di bawah 100, maka petani mengalami defisit sehingga kesejahteraannya menurun. Oleh karena itu, pemantauan dan peramalan NTP menjadi aspek penting dalam perumusan kebijakan pemerintah guna mengendalikan inflasi pada sektor pertanian dan menjaga stabilitas harga pangan dan pengendalian inflasi [2].

Berdasarkan data Badan Pusat Statistik (BPS) Provinsi Jawa Tengah, NTP pada Januari tahun 2014 tercatat sebesar 101,42, kemudian turun hingga 96,77 pada September tahun 2015 dan kembali meningkat dengan rata-

rata 103,27 pada tahun 2020. Fluktuasi NTP dipengaruhi oleh faktor internal seperti produktivitas dan biaya produksi, serta faktor eksternal seperti inflasi, harga komoditas global, dan dinamika ekonomi makro. Pada saat pandemi Covid-19 terlihat pada Maret tahun 2020 ketika NTP menurun menjadi 102,09, namun setelahnya mengalami pemulihan dengan rata-rata 104,56 pada tahun 2021, 108,41 pada 2022, dan 109,83 pada tahun 2023. Puncaknya terjadi pada Juli tahun 2024 saat NTP mencapai 115,21, dengan rata-rata tahunan 112,72, yang mencerminkan kondisi surplus bagi petani [3]. Kondisi ini menunjukkan adanya pola tren jangka panjang sekaligus siklus musiman yang berulang, sehingga diperlukan model analisis yang lebih kompleks daripada pendekatan sederhana.

Penelitian oleh Mangiwa et al. pada tahun 2025 menggunakan model *Autoregressive Integrated Moving Average* (ARIMA) dengan model terbaik yang diperoleh adalah ARIMA(0,1,9) dengan nilai MAPE sebesar 15,01% dan RMSE sebesar 649,702, yang dikategorikan cukup baik untuk peramalan jangka pendek. Namun, penelitian oleh

Mangiwa et al. menunjukkan bahwa semakin jauh periode waktu peramalan, tingkat akurasi model ARIMA cenderung menurun. ARIMA menghasilkan prediksi yang mendatar dan kurang mampu menangkap pola musiman atau fluktuasi jangka panjang, sehingga model dari ARIMA kurang efektif jika diterapkan pada data dengan karakteristik musiman [4][5].

Keterbatasan pada ARIMA dapat diatasi dengan pendekatan dengan model *Seasonal Autoregressive Integrated Moving Average* (SARIMA), pengembangan model dari ARIMA dengan menambahkan komponen musiman atau tahunan. SARIMA mampu menangkap pola berulang seperti siklus bulanan maupun tahunan, sehingga lebih tepat digunakan pada data pertanian yang bersifat musiman. Beberapa penelitian telah menunjukkan keunggulan SARIMA yang lebih akurat dibandingkan ARIMA dalam memodelkan inflasi di Indonesia, terutama karena kemampuan menangkap pola musiman dalam data bulanan [6]. Dengan demikian, pemilihan model SARIMA menjadi relevan untuk menganalisis dan memprediksi NTP.

Di sisi lain, model Exponential Smoothing, terutama *Holt-Winters*, juga menjadi salah satu pendekatan yang banyak digunakan untuk meramalkan data-data deret waktu (*time series*) musiman. Pendekatan ini menggunakan struktur model yang lebih sederhana daripada SARIMA, namun tetap berhasil dalam menyesuaikan tren dan pola musiman yang cukup stabil. Holt-Winters sering digunakan sebagai model pembanding dalam penelitian peramalan karena kemampuannya untuk memberikan hasil yang responsif terhadap perubahan data tanpa proses identifikasi parameter yang kompleks sebagaimana diperlukan oleh SARIMA [7].

Berbeda dengan penelitian sebelumnya, studi ini secara khusus berfokus pada peramalan NTP Provinsi Jawa Tengah periode Januari 2016 sampai Oktober 2025 dengan membandingkan dua model peramalan deret waktu, yaitu SARIMA dan Exponential Smoothing (*Holt-Winters*). Data yang digunakan merupakan data resmi dari BPS Provinsi Jawa Tengah sehingga hasil peramalan dapat menggambarkan kondisi yang sebenarnya.

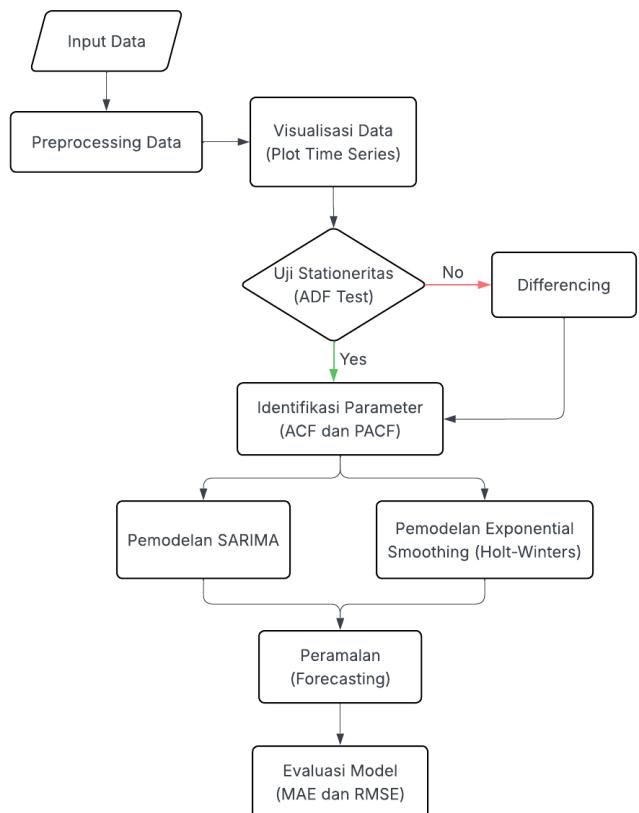
Penelitian ini bertujuan untuk mengetahui model mana yang mampu memberikan hasil peramalan yang lebih akurat dalam memodelkan pola musiman dan fluktuasi NTP. Pendekatan yang digunakan menekankan analisis teknis melalui proses pemodelan, pengukuran akurasi, dan evaluasi performa kedua model. Orisinalitas penelitian ini terletak pada perbandingan langsung antara SARIMA dan Holt-Winters pada data NTP dengan rentang waktu yang panjang dan terbaru, yang masih jarang dilakukan pada penelitian sebelumnya. Dengan adanya studi ini, diharapkan dapat memberikan gambaran mengenai pemilihan model peramalan yang tepat untuk data musiman, khususnya pada bidang pertanian.

Hasil peramalan yang diperoleh dari penelitian ini diharapkan tidak hanya bermanfaat secara akademis, tetapi

jugalah memberikan gambaran yang lebih jelas mengenai kecenderungan NTP di masa mendatang. Informasi ini dapat menjadi bahan pendukung dalam proses analisis dan evaluasi pada sektor pertanian, khususnya dalam memantau perkembangan NTP dan mengantisipasi potensi fluktuasi yang terjadi secara musiman. Dengan adanya hasil peramalan yang lebih akurat, pihak terkait dapat lebih mudah dalam memetakan kondisi sektor pertanian serta menilai efektivitas program atau kebijakan yang sudah berjalan.

II. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan SARIMA untuk meramalkan NTP. Alur penelitian disusun dalam delapan tahapan utama, yaitu input data, preprocessing data, visualisasi data (*plot time series*), uji stasioneritas (ADF test), identifikasi parameter (ACF dan PACF), pemodelan SARIMA, pemodelan Exponential Smoothing, peramalan, dan evaluasi model (MAE dan RMSE). Setiap tahapan terlihat pada flowchart di bawah ini dan dijelaskan setiap tahapannya:



Gambar 1. Alur Penelitian

A. Input Data

Input data merupakan tahap pertama dalam penelitian dengan memasukkan dan menyiapkan data. Pada tahapan ini, dilakukan pengumpulan data dalam satu kesatuan dataset

yang berasal dari sumber primer. Tahapan ini penting karena kualitas input data akan sangat memengaruhi hasil analisis yang diperoleh. Dengan input data yang baik, peneliti dapat memastikan bahwa dataset siap untuk dilakukan tahapan preprocessing.

B. Preprocessing Data

Tahap preprocessing dilakukan untuk memastikan data siap dianalisis. Proses ini meliputi:

1. Pembersihan nama kolom dari spasi atau karakter tersembunyi.
2. Konversi kolom tanggal ke format *datetime* dan penetapan sebagai indeks deret waktu.
3. Penghapusan data yang tidak valid pada kolom tanggal.
4. Penyusunan data berdasarkan urutan waktu.
5. Pengecekan *missing value* dan pemeriksaan statistik deskriptif untuk memahami karakteristik data [8].

Hasil preprocessing menunjukkan bahwa data lengkap dan tepat, sehingga dapat digunakan untuk tahapan selanjutnya.

C. Visualisasi Data

Data NTP yang telah melalui tahap preprocessing kemudian divisualisasikan dalam bentuk grafik deret waktu untuk menampilkan pola tren, fluktuasi, dan pola musiman yang ada. Visualisasi ini sangat penting dalam memberikan gambaran awal mengenai karakteristik data, sehingga membantu dalam pemilihan parameter model SARIMA yang sesuai. Dengan memanfaatkan *Google Colab* dan bahasa pemrograman *Python*, visualisasi data dilakukan menggunakan *matplotlib* dan *seaborn* untuk menghasilkan grafik yang mudah dipahami dan informasi yang jelas. Tahap ini juga memberikan indikasi pola musiman yang berulang, serta fluktuasi jangka panjang dan pendek yang perlu diperhitungkan dalam pemodelan.

D. Uji Stationeritas

Data NTP dilakukan uji stationeritas dengan *Augmented Dickey-Fuller* (ADF). Uji ini dilakukan untuk menentukan apakah deret waktu dengan rata-rata dan variansi yang konstan. Data dianggap stasioner jika p-value kurang dari 0,05 sedangkan jika p-value lebih dari atau sama dengan 0,05 data perlu dilakukan *differencing* yang bertujuan untuk meminimalisir tren dan pola musiman untuk menghindari bias model dalam peramalan [9]. Setelah melakukan *differencing*, dilakukan kembali uji ADF untuk memastikan bahwasanya data sudah stasioner. Rumus uji stationeritas dengan ADF dapat dilihat di bawah ini [10]:

$$\Delta Y_t = \beta_0 + \beta_1 t + \alpha Y_{t-1} + \sum_{i=1}^p \gamma_i \Delta Y_{t-i} + \epsilon_t \quad (1)$$

Keterangan:

- β_0 = Konstanta (*intercept*).
 $\beta_1 t$ = Tren deterministik (opsional, kalau modelnya dengan tren).
 αY_{t-1} = Parameter utama untuk uji unit root.

$\sum_{i=1}^p \gamma_i \Delta Y_{t-i}$ = Tambahan lag untuk mengatasi autokorelasi.

ϵ_t = Nilai error pada waktu t.

E. Identifikasi Parameter

Identifikasi parameter digunakan dengan menganalisis pola pada plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). plot ACF berguna untuk mengidentifikasi komponen *Moving Average* (MA), dengan pola putus-putus yang mengindikasikan orde MA, sedangkan pola lamban yang mengindikasikan komponen *Autoregressive* (AR). Sebaliknya, plot PACF digunakan untuk menentukan komponen AR, di mana pola putus-putus pada PACF mengindikasikan orde AR, sedangkan pola lamban mengindikasikan adanya komponen MA [11].

Analisis gabungan kedua plot ini memungkinkan penentuan nilai parameter orde p (AR) dan q (MA), serta parameter musiman P dan Q pada model SARIMA, sehingga menjadi dasar dalam pemilihan model terbaik sebelum tahap estimasi [12].

Berikut ini merupakan rumus dari ACF [13]:

$$p_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (2)$$

Keterangan:

p_k = Koefisien autocorrelation lag k .

Z_t = Nilai pada waktu t .

\bar{Z} = Rerata data.

n = Jumlah data.

k = Jarak atau lag.

Berikut ini merupakan rumus dari PACF [13]:

$$\varphi_{k,k} = p_k - \sum_{j=1}^{k-1} \varphi_{k,j} p_{k+1-j} \quad (3)$$

Keterangan:

$\varphi_{k,k}$ = Koefisien partial autocorrelation lag k

p_k = Koefisien autocorrelation lag k

$\varphi_{k,j}$ = Koefisien partial autocorrelation lag j

p_{k+1-j} = Koefisien autocorrelation lag $(k+1-j)$

$\sum_{j=1}^{k-1}$ = Penjumlahan dari lag 1 sampai $k-1$

F. Pemodelan SARIMA

Model SARIMA digunakan karena dapat menangkap pola musiman dalam data. Model ini dituliskan dalam bentuk SARIMA(p, d, q)(P, D, Q)s, di mana bagian yang pertama (p, d, q) menunjukkan pola umum, sedangkan bagian yang kedua (P, D, Q)s menunjukkan pola musiman.

Pemilihan model dilakukan dengan beberapa percobaan (*trial and error*) atau dengan teknik pencarian otomatis (*grid search*), kemudian dibandingkan menggunakan kriteria AIC dan BIC, di mana model yang bernilai kecil dipilih sebagai yang terbaik [14]. Karena data yang digunakan adalah bulanan, maka periode musiman ditetapkan $s=12$ agar pola yang berulang setiap tahun dapat terdeteksi. Berikut merupakan rumus dari permodelan SARIMA [15]:

$$\varphi_P(Z^s)\varphi_p(Z)(1-Z^2)^D(1-Z)^dX_t = \theta_Q(Z^s)\theta_q(Z)\epsilon_t \quad (4)$$

Keterangan:

- X_t = Deret waktu periode t
 B = Operator *backshift*, $BX_t = X_{t-1}$.
 s = Panjang periode musiman.
 $(1-B)^d$ = *Differencing* non-musiman orde d .
 $(1-B^2)^D$ = *Differencing* musiman orde D .
 ϵ_t = Nilai error pada waktu t .

G. Pemodelan Exponential Smoothing

Model Exponential smoothing (Holt-Winters) digunakan untuk meramalkan deret waktu dengan pola seasonal/musiman dengan cara melakukan pemulusan (smoothing) pada komponen level, tren, dan musiman sehingga lebih sederhana dan cepat dalam penerapannya. Exponential smoothing memiliki dua jenis pola yaitu aditif dan multiplikatif. Dalam penelitian ini, digunakan model Holt-Winters aditif memiliki tiga komponen utama yaitu level, trend, dan musiman untuk mengukur perubahan dalam data NTP, di mana periodenya diset ke 12 untuk mencocokkan data bulanan [16]. Model ini cocok untuk data dengan fluktuasi musiman yang tetap, seperti data NTP. Rumus utama dalam model Holt-Winters aditif adalah sebagai berikut [17]:

- a. Level (L_t) merupakan nilai dasar dari data pada suatu periode waktu.

$$L_t = \alpha(Y_t - S_{t-m}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (5)$$

- b. Trend (T_t) menggambarkan perubahan data dari satu periode ke periode berikutnya

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (6)$$

- c. Seasonal (S_t) menangkap pola musiman yang berulang setiap periode, seperti fluktuasi tahunan atau bulanan.

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-m} \quad (7)$$

- d. Forecast (F_{t+h}) adalah nilai peramalan untuk horison waktu tertentu (misalnya, 1 bulan atau lebih ke depan).

$$\hat{Y}_{t+h} = L_t + hT_t + S_{t-m+h} \quad (8)$$

Keterangan:

- Y_t = Data aktual pada waktu t
 L_t = Level pada waktu t
 T_t = Trend pada waktu t
 S_t = Komponen musiman pada waktu t
 α, β, γ = Parameter smoothing ($0 < \alpha, \beta, \gamma < 1$)
 m = Periode musiman (misal 12 untuk data bulanan)

H. Peramalan

Tahap peramalan (*forecasting*) dilakukan untuk meramalkan nilai pada data di masa mendatang dengan menggunakan data historis sebelumnya. Peramalan dengan pendekatan SARIMA mempertimbangkan adanya pola musiman dan tren dalam data. Setelah peramalan dibuat, hasilnya dibandingkan dengan data aktual untuk melihat seberapa tepat model dalam memvisualisasikan dinamika deret waktu.

I. Evaluasi Model

Evaluasi model merupakan tahap yang penting dalam analisis deret waktu untuk memastikan hasil prediksi benar-benar akurat dan dipercaya. Tingkat kesalahan yang rendah serta hasil prediksi yang akurat menunjukkan bahwa model dapat diandalkan sebagai alat peramalan dalam analisis. Dua metrik yang digunakan meliputi:

- a. Mean Absolute Error (MAE) merupakan ukuran penilaian yang menghitung rerata nilai absolut antara data aktual dan hasil prediksi. MAE memberikan tingkat kesalahan rerata model dalam sebuah unit yang sama dengan data asli, serta lebih mudah untuk diinterpretasikan [18]. Berikut merupakan rumus dari MAE [19]:

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (8)$$

- b. Root Mean Square Error (RMSE) merupakan ukuran penilaian yang menghitung rerata kuadrat antara nilai aktual dan prediksi yang diakarkan. Indikator ini menilai akurasi model dalam sebuah satuan sama dengan data asli dan lebih sensitif terhadap kesalahan [20]. Berikut merupakan rumus dari RMSE [19]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|^2} \quad (9)$$

Keterangan:

y_t = Penilaian aktual.

\hat{y}_t = Penilaian prediksi.

n = Jumlah data uji.

III. HASIL DAN PEMBAHASAN

A. Hasil Input Data

Data yang sudah di input berisi 117 baris data yang diperoleh dari BPS Provinsi Jawa Tengah dengan rentang waktu Januari tahun 2016 hingga September tahun 2025. Variabel utama yang diprediksi adalah NTP, sedangkan Indeks Diterima Petani (It) dan Indeks Dibayar Petani (Ib) digunakan sebagai indikator pembentuk nilai. Hasil input dari data disusun berdasarkan Tabel 1 di bawah ini.

TABEL I
DATASET NILAI TUKAR PETANI

No	Tanggal	Indeks diterima petani (It)	Indeks dibayar petani (Ib)	Nilai Tukar Petani (NTP)
1	Januari 2016	123.89	122.03	101.52
2	Februari 2016	122.66	122.01	100.53
3	Maret 2016	122.37	123.1	99.4
...
115	Juli 2025	146.25	126.52	115.59
116	Agustus 2025	147.05	126.39	116.35
117	September 2025	147.99	126.67	116.84

Berdasarkan Tabel 1, dapat dilihat bahwa data secara keseluruhan menunjukkan rata-rata NTP selama periode penelitian adalah 104,99 dengan nilai terendah 95,55 dan tertinggi 121,94. Secara tahunan, NTP mengalami fluktuasi yang cukup signifikan, dengan variasi yang terlihat jelas antara nilai terkecil dan tertinggi. Hal ini menunjukkan adanya tren jangka panjang dan pola musiman dalam data NTP, sehingga pemodelan yang dilakukan dalam penelitian ini mempertimbangkan komponen musiman.

B. Hasil Preprocessing

Hasil dari tahapan preprocessing dilakukan pembersihan data dengan memastikan konsistensi format tanggal, penyeragaman nama kolom, serta penghapusan data tidak valid. Hasil pengecekan menunjukkan bahwa tidak terdapat missing value pada seluruh variabel sehingga data dapat digunakan langsung tanpa proses imputasi. Seluruh variabel bertipe numerik dan telah terurut berdasarkan indeks waktu seperti pada Tabel 2 di bawah ini.

TABEL II
HASIL STATISTIK DESKRIPSI

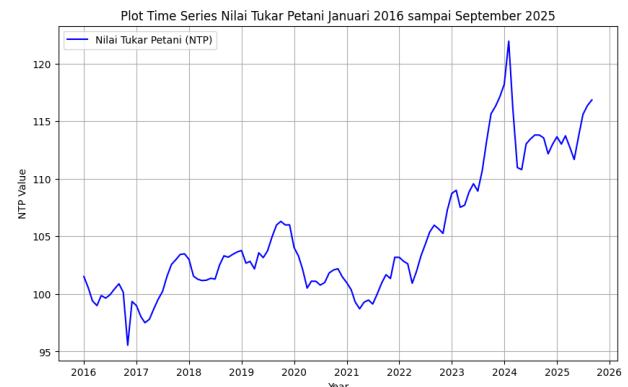
	Indeks diterima petani (lt)	Indeks dibayar petani (lb)	Nilai Tukar Petani (NTP)
Count	117	117	117
Mean	127.81	121.61	104.99
Std	12.62	9.42	5.69
Min	106.85	105.55	95.55
25%	118.5	114.26	100.98
50%	128.64	123.02	103.15
75%	138.58	127.82	108.84
Max	148.86	137.92	121.94

Hasil statistik deskriptif pada Tabel 2 menunjukkan bahwa rata-rata NTP selama periode penelitian adalah 104,99 dengan rentang nilai terendah 95,55 dan tertinggi 121,94. Median NTP sebesar 103,15 mengindikasikan bahwa setengah dari data memiliki nilai di bawah 103,15 dan setengahnya lagi di atas nilai tersebut. Kuartil pertama (25%) berada pada 100,98, dan kuartil ketiga (75%) pada 108,84, yang menunjukkan bahwa sebagian besar data terdistribusi antara 100,98 hingga 108,84. Standar deviasi sebesar 5,69 menunjukkan bahwa variasi NTP relatif kecil, yang berarti pergerakan NTP cenderung stabil dari waktu ke waktu. Secara keseluruhan, data NTP menunjukkan kecenderungan konsisten, meskipun terdapat fluktuasi musiman atau tahunan yang perlu diperhatikan dalam analisis lebih lanjut.

C. Hasil Visualisasi Data

Selanjutnya dataset yang sudah di preprocessing dibuat grafik perkembangan NTP periode Januari 2016 sampai

September 2025 yang menunjukkan fluktuasi dengan tren meningkat dalam jangka panjang seperti pada Gambar 2.



Gambar 2. Grafik NTP Januari 2016 sampai September 2025

Pada Gambar 2 grafik menunjukkan pergerakan NTP dari Januari 2016 hingga September 2025. Pada awal periode, NTP relatif stabil di kisaran 95 sampai 102, namun mengalami penurunan pada tahun 2016 dan 2020. Penurunan tersebut diduga dipengaruhi oleh faktor eksternal seperti kondisi ekonomi yang kurang baik serta dampak pandemi. Sejak tahun 2021, NTP mengalami peningkatan yang signifikan, mencapai puncaknya di atas 120 pada awal tahun 2024, sebelum akhirnya kembali stabil di kisaran 112 hingga 115 pada tahun 2025. Secara keseluruhan, tren ini menunjukkan adanya perbaikan daya tukar petani dalam dekade terakhir, meskipun terdapat fluktuasi yang dipengaruhi oleh faktor eksternal.

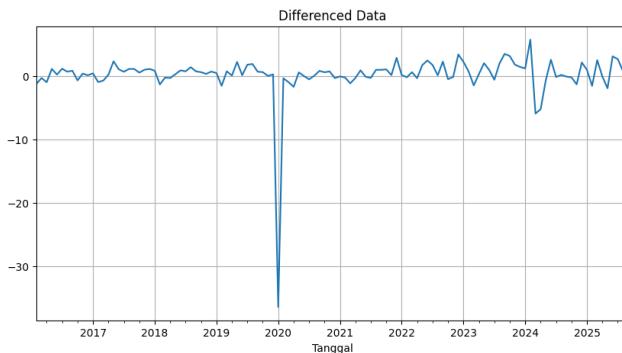
D. Hasil Uji Stationeritas

Pengujian stasioneritas dalam penelitian ini dilakukan menggunakan uji ADF untuk memastikan apakah data deret waktu NTP memenuhi asumsi stasioner sebelum dilakukan pemodelan. Hasil uji ADF ditunjukkan pada Tabel 3.

TABEL III
HASIL UJI STATIONER DENGAN ADF

Uji ADF				
Statistik	P-Value	Critical Value (1%)	Critical Value (5%)	Critical Value (10%)
-1.2061	0.6709	-3.4880	-2.8868	-2.5802

Berdasarkan hasil uji ADF pada Tabel 3 diperoleh nilai statistik pada uji ADF sebesar -1.2061 dengan p-value 0.6709 (> 0.05). Hal ini menunjukkan bahwa data NTP belum stasioner, sehingga diperlukan transformasi lebih lanjut. Untuk mengatasi hal tersebut, dilakukan proses differencing.



Gambar 3. Differencing Data

Pada Gambar 3, proses *differencing* data memperlihatkan perbandingan antara data asli dan hasil *differencing*. Data asli menunjukkan adanya tren naik, terutama setelah tahun 2021, sedangkan data hasil *differencing* berfluktuasi di sekitar nol. Hal ini mengindikasikan bahwa tren telah berhasil dihilangkan. Setelah proses *differencing*, selanjutnya dilakukan kembali uji stasioneritas dengan menggunakan uji ADF pada data hasil *differencing*.

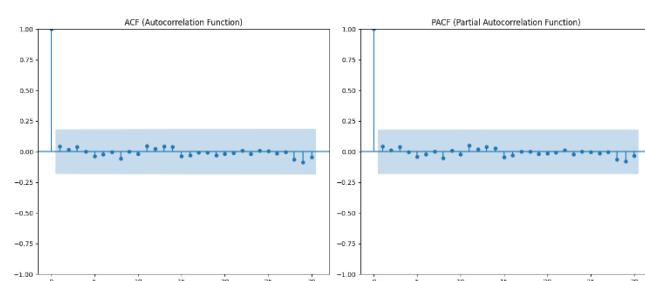
TABEL IV
HASIL UJI STATIONER SETELAH DIFFERENCING

Uji ADF				
Statistik	P-Value	Critical Value (1%)	Critical Value (5%)	Critical Value (10%)
-10.1911	6.3168	-3.4885	-2.887	-2.5803

Hasil uji ADF pada Tabel 4 menunjukkan nilai Statistik ADF sebesar -10.1911 dengan $p\text{-value} = 6.3168 < 0.05$. Hal ini mengindikasikan penolakan terhadap hipotesis nol (H_0), yang berarti data hasil *differencing* telah stasioner.

E. Hasil Identifikasi Parameter

Setelah data dipastikan stasioner, langkah selanjutnya yaitu mengidentifikasi parameter model SARIMA melalui analisis ACF dan PACF.



Gambar 4. Plot ACF dan PACF Differencing

Pada Gambar 4 memperlihatkan plot ACF dan PACF yang digunakan untuk identifikasi parameter model SARIMA. Pada plot ACF (kiri), terlihat bahwa autokorelasi signifikan hanya terjadi pada lag pertama, sementara setelah itu nilai

ACF menurun dan tidak ada autokorelasi signifikan. Hal ini menunjukkan bahwa model MA(1) mungkin cocok untuk menangkap komponen *moving average* dalam model. Sementara itu, pada plot PACF (kanan), terlihat penurunan tajam setelah lag pertama, yang mengindikasikan bahwa model AR(1) dapat menangkap komponen *autoregressive* pada model SARIMA. Secara keseluruhan, plot ACF dan PACF ini memberikan petunjuk penting dalam memilih parameter p dan q yang optimal untuk model SARIMA yang akan digunakan. Dengan demikian, beberapa kombinasi orde AR (p), *differencing* (d), dan MA (q) serta komponen musiman (P , D , Q , s), di mana $s = 12$ yang dapat dibentuk sebagai kandidat model awal SARIMA. Kandidat model awal tersebut ditunjukkan pada Tabel 5.

TABEL V
KANDIDAT MODEL AWAL SARIMA

No.	Model SARIMA
1	(1,0,0)(0,2,1,12)
2	(0,1,1)(0,1,2,12)
3	(2,1,0)(0,0,1,12)
4	(2,1,2)(1,0,0,12)
5	(1,1,1)(1,1,1,12)

Keterangan pada Tabel 5 adalah model SARIMA(1,0,0)(0,2,1,12) dipilih untuk menangkap pola musiman dominan dengan diferensiasi musiman yang kuat. Model SARIMA(0,1,1)(0,1,2,12) mengakomodasi tren dengan efek musiman yang cukup kompleks. Model SARIMA(2,1,0)(0,0,1,12) menekankan pada ketergantungan jangka pendek melalui komponen AR orde dua dengan musiman sederhana. Model SARIMA(2,1,2)(1,0,0,12) mengombinasikan komponen AR dan MA baik pada bagian non-musiman maupun musiman. Sementara itu, model SARIMA(1,1,1)(1,1,1,12) dianggap sebagai kandidat yang seimbang karena mampu menangkap tren, pola jangka pendek, serta efek musiman secara bersamaan.

F. Hasil Pemodelan SARIMA

Setelah kandidat permodelan diperoleh, dilakukan proses estimasi dan uji diagnostik residual. Langkah awal pada permodelan ini dengan membagikan data menjadi data *training* dan data *testing*. Data *Training* berguna untuk membangun model, sementara Data *testing* berguna untuk pengujian akurasi model untuk menilai kemampuan model untuk meramalkan data baru secara lebih objektif sebagaimana ditunjukkan pada Tabel 6.

TABEL VI
HASIL PEMBAGIAN DATASET

Dataset	Jumlah Observasi
Training Data	105
Test Data	12

Setelah dilakukan pembagian data, langkah selanjutnya yaitu melakukan estimasi parameter pada model SARIMA yang telah terpilih. Kemudian hasil untuk model $(1,1,1)(1,1,1,12)$ digunakan untuk mengetahui kontribusi masing-masing komponen dalam model seperti yang ditunjukkan pada Tabel 7 di bawah ini.

TABEL VII
HASIL ESTIMASI PARAMETER

Parameter	Koefisien	Std. Error	Z	P-Value
ar.L1	-0.0648	5.052	-0.013	0.990
ma,L1	0.1208	5.059	0.024	0.981
ar.SL12	-0.0028	0.100	-0.028	0.977
am.SL12	-0.9991	54.678	-0.018	0.985
sigma2	14.8460	810.639	0.018	0.985

Hasil estimasi model SARIMA menunjukkan bahwa semua parameter, baik non-musiman ($AR(1) = -0.0648$, $MA(1) = 0.1208$) maupun musiman ($AR(12) = -0.0028$, $MA(12) = -0.9991$), memiliki p-value di atas 0,05, yang berarti tidak signifikan secara statistik. Koefisien dan standar error yang besar menunjukkan bahwa kontribusi parameter-parameter tersebut terhadap model cukup lemah. Varians residual ($\sigma^2 = 14.8460$) yang tinggi mengindikasikan error model yang cukup besar. Meskipun demikian, model masih bisa digunakan untuk peramalan karena secara keseluruhan tetap dapat mengikuti pola data meskipun parameter individualnya tidak signifikan. Estimasi parameter, pemilihan model SARIMA juga didasarkan pada kriteria informasi seperti AIC, BIC, dan HQIC. Semakin kecil nilai kriteria ini, maka model dianggap lebih tepat dalam menampilkan data dengan kompleksitas yang minimal. Nilai kriteria pemilihan model dapat dilihat pada Tabel 8.

TABEL VIII
HASIL KRITERIA PEMILIHAN MODEL

Statistik	Nilai
AIC	545.159
BIC	557.768
HQIC	550.248

Berdasarkan hasil perhitungan, model $(1,1,1)(1,1,1,12)$ menghasilkan nilai AIC sebesar 545.159, BIC sebesar 557.768, dan HQIC sebesar 550.248. Nilai ini menjadi dasar untuk membandingkan dengan kandidat model lain dalam menentukan model yang menunjukkan hasil terbaik.

TABEL IX
HASIL UJI DIAGNOSVISUALISTIK RESIDUAL

Uji	Nilai	P-Value
Ljung-Box (Q)	0.00	0.98
Jarque-Bera (JB)	22.57	0.00
Heteroskedastisitas (H)	10108.88	0.00

Selanjutnya dilakukan uji diagnostik residual untuk memastikan model memenuhi asumsi dasar analisis *time*

series. Hasil uji diagnostik residual ditunjukkan pada Tabel 9. Tabel 9 hasil uji *Ljung-Box* menampilkan p-value sebesar 0.98 lebih dari 0.05 jadinya tidak terdapat *autokorelasi* pada residual. Namun, hasil dari uji *Jarque-Bera* memperlihatkan p-value sebesar 0.00, yang berarti residual tidak terdistribusi normal. Sementara itu, uji *Heteroskedastisitas* menghasilkan nilai sebesar 10108.88 dengan p-value 0.00 yang menandakan adanya indikasi ketidakstabilan varians residual, tetapi tidak menunjukkan masalah yang cukup serius untuk mempengaruhi akurasi model secara signifikan. Dengan demikian, untuk model $(1,1,1)(1,1,1,12)$ dapat dikatakan sudah cukup baik karena terbebas dari *autokorelasi* dan *heteroskedastisitas*, meskipun asumsi normalitas residual belum sepenuhnya terpenuhi.

G. Hasil Pemodelan Exponential Smoothing

Pada tahap ini, model Exponential Smoothing (Holt-Winters) diterapkan untuk NTP Provinsi Jawa Tengah. Model yang digunakan adalah model aditif. Proses estimasi parameter dilakukan menggunakan data latih periode Januari 2014 sampai Desember 2022 dengan komponen level, trend, dan seasonal yang disesuaikan untuk mencocokkan pola data yang ada. Pada eksperimen ini, periode musiman diset menjadi 12, mengingat data yang digunakan adalah data bulanan. Hasil estimasi model yang meliputi nilai level, trend, dan seasonal ditunjukkan pada Tabel 10 di bawah ini.

TABEL X
ESTIMASI KOMPONEN MODEL

Komponen	Nilai
Level	138.292
Trend	0.1335
Seasonal	[0.248, 0.189, 0.159, 0.130, 0.100, 0.069, 0.039, 0.009, -0.020, -0.050, -0.079, -0.109]

Pada Tabel 10 menunjukkan nilai level yang dihitung sebesar 138.292 menunjukkan nilai rata-rata dasar NTP pada periode terakhir yang dihitung. Komponen trend, dengan nilai 0.1335, menunjukkan adanya kenaikan kecil dalam NTP dari satu periode ke periode berikutnya, menandakan tren positif yang stabil. Sementara itu, komponen *seasonal* menggambarkan pola musiman yang berulang setiap tahun, dengan kontribusi positif pada awal tahun (Januari hingga Maret) dan penurunan pada akhir tahun (November dan Desember), yang mencerminkan fluktuasi musiman dalam data NTP.

H. Hasil Peramalan

Setelah proses pemodelan SARIMA dan Exponential Smoothing dilakukan, tahap selanjutnya adalah melakukan peramalan (*forecasting*) NTP dengan visualisasi grafik seperti Gambar 5 di bawah ini.



Gambar 5. Grafik prediksi NTP

Pada Gambar 5 menunjukkan perbandingan hasil peramalan NTP Provinsi Jawa Tengah hingga tahun 2027 menggunakan model SARIMA dan Exponential Smoothing. Data aktual NTP dari 2016 hingga 2024 (garis biru) menunjukkan fluktuasi signifikan, terutama pada 2020. Model SARIMA (garis oranye putus-putus) mengikuti pola data dengan baik meskipun ada sedikit deviasi, sedangkan Exponential Smoothing (garis hijau putus-putus) memberikan prediksi yang lebih stabil dan konsisten. Pada peramalan jangka panjang (Oktober 2025 sampai Desember 2027), kedua model menunjukkan stabilitas, namun dengan rentang prediksi yang semakin melebar, yang mencerminkan ketidakpastian yang lebih besar seiring bertambahnya horizon waktu. Secara keseluruhan, Exponential Smoothing cenderung memberi hasil dari peramalan yang sedikit lebih halus dan stabil dibandingkan SARIMA, sedangkan SARIMA lebih responsif terhadap perubahan tren jangka pendek.

Meskipun keduanya menunjukkan pola musiman yang serupa, hasil evaluasi menunjukkan bahwa Exponential Smoothing memiliki sebuah tingkat kesalahan yang lebih rendah, sehingga dapat dianggap lebih akurat untuk peramalan NTP jangka menengah hingga panjang.

I. Hasil Evaluasi Model

Setelah dilakukan perbandingan pada proses peramalan, model SARIMA dan Exponential Smoothing dievaluasi dengan dua metrik, yaitu MAE dan RMSE. Metrik tersebut dipilih karena dapat menampilkan penggambaran yang komprehensif mengenai tingkat akurasi dalam memprediksi data deret waktu, baik dari sisi rata-rata kesalahan absolut, penyimpangan kuadrat rata-rata, maupun persentase kesalahan relatif. Hasil dari evaluasi model dapat dilihat pada Tabel 11 di bawah ini.

TABEL XI
HASIL EVALUASI MODEL

Metrik	Nilai SARIMA	Nilai Exponential Smoothing
MAE	4.1671	4.1112
RMSE	4.7146	4.6440

Berdasarkan Tabel 11, perbandingan antara model SARIMA dan Exponential Smoothing (Holt-Winters) menggunakan

dua metrik evaluasi, yaitu MAE dan RMSE, menunjukkan bahwa model Exponential Smoothing sedikit lebih akurat dibandingkan dengan SARIMA. Untuk MAE, nilai model SARIMA adalah 4.1671, sedangkan model Exponential Smoothing menghasilkan nilai 4.1112, yang menunjukkan bahwa model Exponential Smoothing memiliki kesalahan rata-rata yang lebih kecil. Begitu pula dengan RMSE, di mana model SARIMA memiliki nilai 4.7146, sedangkan model Exponential Smoothing mencatatkan nilai 4.6440. Meskipun perbedaan antara kedua model tidak terlalu besar, hasil ini memperlihatkan bahwa Exponential Smoothing lebih baik dalam memprediksi data NTP, dengan kesalahan yang lebih rendah pada kedua metrik yang digunakan.

IV. KESIMPULAN

Penelitian ini membandingkan kinerja model SARIMA dan Exponential Smoothing (Holt-Winters) dalam meramalkan NTP Provinsi Jawa Tengah. Berdasarkan hasil evaluasi model menggunakan metrik MAE dan RMSE, model SARIMA(1,1,1)(1,1,1,12) menunjukkan bahwa prediksi untuk data dari Januari 2016 hingga September 2025 menghasilkan nilai MAE 4.1671 dan RMSE 4.7146, yang mengindikasikan bahwa model ini memberikan prediksi dengan kesalahan relatif rendah. Hasil peramalan untuk periode Oktober 2025 hingga Desember 2027 menunjukkan bahwa NTP cenderung stabil dengan pola musiman yang teratur, meskipun ketidakpastian meningkat seiring bertambahnya horizon waktu.

Di sisi lain, Exponential Smoothing (Holt-Winters) memberikan hasil yang lebih akurat, dengan nilai MAE yang lebih rendah dan RMSE lebih kecil dibandingkan model SARIMA, yang mengindikasikan kesalahan prediksi yang lebih kecil. Meskipun perbedaan antara kedua model tidak signifikan besar, Exponential Smoothing lebih stabil dan lebih responsif terhadap fluktuasi musiman dibandingkan SARIMA.

Hasil penelitian ini menunjukkan bahwa baik SARIMA maupun Exponential Smoothing dapat diandalkan untuk memprediksi NTP, tetapi Exponential Smoothing lebih sederhana dan lebih stabil dalam peramalan jangka panjang. Oleh karena itu, Exponential Smoothing bisa menjadi alternatif yang baik untuk model peramalan yang lebih kompleks seperti SARIMA, terutama ketika data musiman relatif stabil.

Namun, terdapat catatan bahwa penelitian ini punya keterbatasan terkait dengan kurangnya faktor eksternal pada peramalan NTP. Modelnya hanya mengandalkan data historis NTP tanpa mempertimbangkan faktor-faktor ekonomi atau lingkungan. Disarankan juga untuk mempertimbangkan model peramalan lain seperti ARIMAX, VAR, atau model berbasis *machine learning* (misalnya LSTM), serta memasukkan faktor eksternal seperti inflasi, curah hujan, atau harga komoditas global untuk meningkatkan ketepatan hasil prediksi dan memperkaya analisis NTP.

DAFTAR PUSTAKA

- [1] N. D. Andriatmoko, S. Muljaningsih, F. E. Supriatin, and N. Tausikal, "Nilai Tukar Petani (NTP) Kabupaten Trenggalek tahun 2022," *J. Ekon. Pertan. dan Agribisnis*, vol. 8, no. 3, pp. 1222–1237, 2024.
- [2] L. S. M. Indah, W. A. Zakaria, and D. M. Sari, "Pengaruh Inflasi, PDRB, Suku Bunga, dan Tenaga Kerja terhadap Nilai Tukar Petani Provinsi Lampung," *J. Ekon. Pertan. dan Agribisnis*, vol. 7, no. 3, pp. 1099–1111, 2023.
- [3] "Nilai Tukar Petani (NTP) Provinsi Jawa Tengah, 2014–2024," Badan Pusat Statistik Provinsi Jawa Tengah. Accessed: Sep. 01, 2025. [Online]. Available: <https://jateng.bps.go.id/id/statistics-table/2/ODYjMg==/nilai-tukar-petani.html>
- [4] R. D. D. Mangiwa, R. Siregar, S. D. Sari, and N. Agustina, "Application of the Arima Model in Forecasting Ethereum Prices," *Param. J. Mat. Stat. dan Ter.*, vol. 4, no. 1, pp. 81–94, 2025, doi: 10.30598/parameterv4i1pp81-94.
- [5] M. Y. T. Sulistyono, E. S. Pane, E. M. Yuniarso, and M. H. Purnono, "Correlation Analysis Approach Between Features and Motor Movement Stimulus for Stroke Severity Classification of EEG Signal Based on Time, Frequency, and Signal Decomposition Domain," *J. Nas. Pendidik. Tek. Inform. JANAPATI*, vol. 13, no. 3, pp. 597–611, 2024, doi: 10.22266/ijies2024.1231.91.
- [6] A. R. Wahyuningtyas, W. P. Pratiwi, R. Wasono, and T. W. Utami, "Peramalan Indeks Harga Konsumen Kabupaten Banyumas dengan Metode SARIMA," *J. Litbang Edusaintech*, vol. 3, no. 1, pp. 56–60, 2021.
- [7] M. Syafar *et al.*, "Perbandingan Metode Sarima Dan Exponential Smoothing Dalam Memprediksi Curah Hujan Di Kabupaten Bangka Tengah," *J. Fraction*, vol. 4, no. 2, pp. 41–48, 2024.
- [8] A. Prayuda and I. Pratama, "Prediksi Jumlah Kedatangan Wisatawan Mancanegara di Indonesia Berdasarkan Pintu Masuk Kedatangan Udara," *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 9, no. 2, pp. 232–241, 2024, doi: 10.36341/rabit.v9i2.4787.
- [9] F. A. N. Fauzi, R. Santoso, and D. A. I. Maruddani, "Pemodelan Data Time Series Menggunakan Pendekatan Regresi Polinomial Lokal pada Data Harga Saham MDKA," *Indones. J. Appl. Stat.*, vol. 6, no. 2, pp. 186–197, 2023, doi: 10.13057/ijas.v6i2.80118.
- [10] A. Roza, E. S. Violita, and S. Aktivani, "Study of Inflation using Stationary Test with Augmented Dickey Fuller & Phillips-Peron Unit Root Test (Case in Bukittinggi City Inflation for 2014–2019)," *EKSAKTA Berk. Ilm. Bid. MIPA*, vol. 23, no. 02, pp. 106–116, 2022, doi: 10.24036/eksakta/vol23-iss02/303.
- [11] L. Mauditia, N. Imro'ah, and W. Andani, "Prediksi Jumlah Permintaan Darah UTD PMI Kota Pontianak Menggunakan ARIMA-Kalman Filter," *Indones. J. Appl. Stat.*, vol. 7, no. 1, pp. 73–86, 2024, doi: 10.13057/ijas.v7i1.85958.
- [12] P. A. Andila, "Penerapan Model Arma (Autoregressive Moving Average) Dalam Meramalkan Harga Cabai di Kota Bukittinggi," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 2, pp. 223–231, 2025, doi: 10.23960/jite.v13i2.6148.
- [13] S. Halim, B. Mulyawan, and M. D. Lauro, "Prediksi Jumlah Wisatawan Mancanegara ke Indonesia Berdasarkan Kebangsaan Menggunakan SARIMA," *J. Ilmu Komput. dan Sist. Inf.*, vol. 13, no. 1, pp. 1–8, 2025.
- [14] R. Kruba, H. Sofyan, D. Marshanda, D. Rizki, N. Syazana, and Rahmadhania, "Peramalan Saham Indofood di Indonesia Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA)," *J. Manaj. DAN Keuang.*, vol. 4, no. 1, pp. 102–117, 2025, doi: 10.32665/statkom.v4i1.4424.
- [15] H. N. D. Fortuna and A. Oktaviarina, "Peramalan Jumlah Produksi Padi Kabupaten Ngawi Menggunakan Metode SARIMA-ARCH," *MATHunesa J. Ilm. Mat.*, vol. 12, no. 2, pp. 418–427, 2024, doi: 10.26740/mathunesa.v12n2.p418-427.
- [16] I. R. Amalia, T. Widiharh, and Tarno, "Holt Winters Exponential Smoothing Untuk Meramalkan Produk Domestik Bruto Di Indonesia," *J. Gaussian*, vol. 13, no. 1, pp. 219–229, 2024, doi: 10.14710/j.gauss.13.1.219-229.
- [17] A. A. Asmaradana and E. Widodo, "Penerapan Metode Peramalan Double Exponential Smoothing Pada Indeks Harga Konsumen Kota Yogyakarta," *Emerg. Stat. Data Sci. J.*, vol. 1, no. 1, pp. 30–36, 2023.
- [18] R. D. Syah, "Performa Algoritma User K-Nearest Neighbors pada Sistem Rekomendasi di Tokopedia," *J. Inform. Univ. Pamulang*, vol. 5, no. 3, pp. 302–306, 2020, doi: 10.32493/informatika.v5i3.6312.
- [19] L. S. Ihzaniah, A. Setiawan, and R. W. N. Wijaya, "Perbandingan Kinerja Metode Regresi K-Nearest Neighbor dan Metode Regresi Linear Berganda pada Data Boston Housing," *Jambura J. Probab. Stat.*, vol. 4, no. 1, pp. 17–29, 2023, doi: 10.34312/jjps.v4i1.18948.
- [20] A. Widianti and I. Pratama, "Penanganan Missing Values dan Prediksi Data Timbunan," *RABIT J. Teknol. dan Sist. Inf. Univrab*, vol. 9, no. 2, pp. 242–251, 2024.