



Penerapan Metode *Autoregressive Integrated Moving Average* (ARIMA) dalam Peramalan Nilai Tukar Rupiah terhadap Dollar Amerika Pada Tahun 2022-2024

Sesilia Putri Subandi¹, Dhea Amelia Putri², Natasya Ega Lina Marbun³, Rayan Koemi Karuby⁴, Khusnun Nisa⁵, Ganiya Syazwa⁶, Luluk Muthoharoh⁷, Mika Alvionita⁸, Ira Safitri⁹

1, 2, 3, 4, 5, 6, 7, 8, 9 *Sains Data, Institut Teknologi Sumatera*

¹sesilia.122450012@student.itera.ac.id, ²dhea.122450004@student.itera.ac.id,

³natasya.122450024@student.itera.ac.id, ⁴rayan.122450038@student.itera.ac.id, ⁵khusnun.122450078@student.itera.ac.id,

⁶ganiya.122450073@student.itera.ac.id, ⁷luluk.muthoharoh@sd.itera.ac.id, ⁸mika.alvionita@sd.itera.ac.id, ⁹ira.safitri@sd.itera.ac.id

Corresponding author email: luluk.muthoharoh@sd.itera.ac.id

Abstract: Indonesia's economic state is significantly affected by changes in the Rupiah's exchange rate relative to foreign currencies, particularly the United States Dollar (USD), which serves as a key indicator for evaluating national economic stability. This exchange rate is affected by several external elements like inflation and interest rates, and significantly impacts the cost of products, foreign investment movements, and the economic stability of the nation. This research predicts the Rupiah to USD exchange rate for the time frame from October 2022 to December 2024 by employing the Autoregressive Integrated Moving Average (ARIMA) technique to assess the effects of these variations. Through the process of identifying the model, estimating parameters, and assessing information criteria, the optimal model was identified as ARIMA (2,1,2), selected for its lowest Akaike's Information Criterion (AIC) value of 4781.886. This model yields a Mean Absolute Percentage Error (MAPE) of 26%, suggesting that the forecasting accuracy falls within the moderate range. Consequently, the ARIMA (2,1,2) model serves as a quantitative tool for forecasting the fluctuation of the Rupiah exchange rate relative to the USD to aid in economic decision making.

Keywords: ARIMA, Rupiah exchange rate, Stationarity

Abstrak: Kondisi perekonomian Indonesia sangat dipengaruhi oleh fluktuasi nilai tukar Rupiah terhadap mata uang asing, khususnya Dollar Amerika Serikat (USD), yang merupakan salah satu indikator utama dalam menilai kestabilan ekonomi nasional. Pergerakan nilai tukar ini ditentukan oleh sejumlah faktor eksternal, seperti tingkat inflasi dan suku bunga, serta berdampak besar terhadap harga barang, arus investasi asing, dan ketahanan ekonomi negara. Untuk mengantisipasi dampak dari fluktuasi tersebut, penelitian ini melakukan prediksi nilai tukar Rupiah terhadap USD untuk periode Oktober 2022 hingga Desember 2024 menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA). Berdasarkan proses penentuan model, estimasi parameter, dan evaluasi kriteria informasi, diperoleh model terbaik yaitu ARIMA (2,1,2) terpilih karena memiliki nilai Akaike's Information Criterion (AIC) terkecil, yakni sebesar 4781.886. Model ini menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 26%, yang menunjukkan bahwa tingkat akurasi peramalan berada pada kategori moderat. Dengan demikian, model ARIMA (2,1,2) layak digunakan sebagai alat bantu dalam memprediksi pergerakan nilai tukar Rupiah terhadap USD secara kuantitatif guna mendukung pengambilan keputusan ekonomi.

Kata kunci: ARIMA, nilai tukar rupiah, stasioneritas

I. PENDAHULUAN

Stabilitas perekonomian suatu negara merupakan landasan utama dalam mewujudkan pembangunan berkelanjutan. Dalam konteks Indonesia, kondisi ekonomi nasional sangat dipengaruhi oleh dinamika ekonomi global, terutama melalui fluktuasi pertukaran nilai mata uang. Nilai tukar Rupiah terhadap mata uang asing, terutama Dollar AS, [1]. Nilai tukar memiliki peran strategis dalam perdagangan internasional, investasi asing, serta perumusan kebijakan moneter dan fiskal. Ada banyak variabel yang memengaruhinya, seperti kebijakan bank sentral, inflasi, suku bunga, dan keadaan ekonomi dan geopolitik di seluruh dunia. Harga barang impor dan ekspor, arus modal, dan stabilitas pasar keuangan domestik semuanya dapat dipengaruhi langsung oleh



fluktuasi nilai tukar. Oleh karena itu, peramalan nilai tukar yang akurat sangat penting bagi pelaku usaha, pembuat kebijakan, dan masyarakat luas.

Dalam kurun waktu 2022 hingga 2024, nilai tukar Rupiah menunjukkan dinamika yang mencerminkan respons terhadap tekanan eksternal. Di akhir 2022, Rupiah berada pada posisi Rp15.615 per USD, sedikit menguat menjadi Rp15.575 pada 2023, namun kembali melemah ke Rp15.820 pada tahun 2024. Inflasi Amerika Serikat yang tinggi, mencapai 3,48%, dan keputusan *Federal Reserve* (atau *The Fed*) untuk mempertahankan suku bunga acuan yang tinggi, adalah beberapa faktor yang menyebabkan pelemahan ini [2]. Kebijakan tersebut mendorong penguatan USD secara global, melemahkan mata uang negara berkembang seperti Rupiah, serta berdampak pada menurunnya minat investor dan fluktuasi harga saham di dalam negeri.

Dalam menghadapi volatilitas nilai tukar, penggunaan metode peramalan deret waktu (*time series forecasting*) menjadi pendekatan yang banyak diterapkan untuk memahami dan mengantisipasi tren masa depan. Deret waktu merupakan sekumpulan data yang dicatat secara kronologis dan dapat dianalisis untuk mengidentifikasi pola atau kecenderungan jangka pendek maupun panjang. *Autoregressive Integrated Moving Average* (ARIMA), yang dikenal efektif dalam memodelkan data non-stasioner, adalah salah satu metode yang paling umum digunakan. Model ini menggabungkan komponen autoregresif, perbedaan (*differencing*), dan rata-rata bergerak, sehingga mampu menangkap tren serta pola musiman dalam data [3], [4].

Tujuan dari penelitian ini adalah untuk memodelkan dan meramalkan nilai tukar Rupiah terhadap Dollar Amerika Serikat (USD) dari Oktober 2022 hingga Desember 2024. Ini akan dilakukan dengan menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) sebagai pendekatan statistik *time series*. Kebaruan dari penelitian ini terletak pada penggunaan data pasca-pandemi COVID-19 yang mencerminkan dinamika ekonomi global terkini, termasuk ketidakstabilan pasar dan perubahan kebijakan moneter internasional yang memengaruhi nilai tukar. Selain itu, tujuan penelitian ini adalah untuk mengevaluasi tingkat akurasi model ARIMA dengan menggunakan indikator seperti Kriteria Informasi Akaike (AIC) dan Kesalahan Rata-rata Persentase (MAPE). Tujuannya adalah untuk mengetahui seberapa efektif model dalam peramalan jangka menengah. Penelitian ini diharapkan dapat berfungsi sebagai referensi analitis untuk mendukung kebijakan ekonomi, khususnya untuk menjaga kestabilan nilai tukar Rupiah di tengah tantangan ekonomi global yang terus meningkat.

II. METODE PENELITIAN

II.1. Deret Waktu (*Time Series*)

Data deret waktu (*time series*) merupakan kumpulan data pengamatan maupun data amatan dengan bentuk urutan waktu (*sequential*). Data pengamatan pada deret waktu sendiri memiliki perbedaan dengan data pengamatan dalam *cross section*. Pada data *cross section* antara satu amatan dan amatan lain harus independen atau saling bebas, sedangkan data deret waktu hasil observasi satu dengan observasi lain saling terikat atau memiliki korelasi [5]. Sedangkan analisis deret waktu merupakan penerapan analisis statistik dalam memprediksi kemungkinan situasi di masa depan [6]. Pola pada data deret waktu diklasifikasikan menjadi empat kelompok yaitu pola tren, pola musiman, pola siklis, dan pola horizontal [7].

II.2. Stasioneritas

Stasioner dapat diartikan bahwa kenaikan dan penurunan data berlebih dinyatakan tidak ada, yang berarti data tersebar di sekitar nilai yang serupa. Pada data tidak stasioner, diferensiasi akan dilakukan menggunakan nilai selisih periode data hingga data menjadi stasioner [8]–[10]. Waktu yang tidak lagi mempengaruhi data deret waktu, maka data tersebut dikatakan stasioner. Menentukan kestasioneran data dapat berdasarkan rataan dan ragam [7].

- a. Stasioner dalam rataan, yang artinya rata-rata pada data tersebut tetap dan tidak terdapat pola tren pada data.
- b. Stasioner dalam ragam, yang artinya perubahan data yang stabil sepanjang waktu.



Stasioneritas diuji terhadap rata-rata untuk deret waktu biasanya dilakukan dengan uji ADF (*Augmented Dickey-Fuller*). Rumusan hipotesis pengujian stasioneritas sebagai berikut:

$$H_0: \gamma = 0 \text{ (Tidak stasioner)}$$

$$H_1: \gamma \neq 0 \text{ (Stasioner)}$$

II.3. *Autoregressive Integrated Moving Average* (ARIMA)

Box dan Jenkins ditahun 1970 memperkenalkan sebuah model analisis deret waktu yang menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA). Model ARIMA merupakan bentuk model ARMA (p,q) non stasioner. Setelah model ARMA melalui proses diferensiasi sebanyak d hingga mencapai stasioner, maka bentuk model menjadi ARIMA (p,d,q). Model ARIMA cocok dalam memprediksi dalam jangka waktu yang singkat, sehingga akurasi dinilai kurang baik dalam memprediksi jangka waktu yang panjang [6]. Bentuk umum dari model persamaan ARIMA (p,d,q) adalah sebagai berikut.

$$\phi_p(B)(1 - B)^d Z_t = \theta_0 + \theta_q(B)a_t \tag{1}$$

dengan rumus AR:

$$\phi_p(B) = (1 - \phi_1 B^1 - \phi_2 B^2 - \dots - \phi_p B^p) \tag{2}$$

dengan rumus MA:

$$\theta_q(B) = (1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q) \tag{3}$$

Keterangan:

Z_t : Data observasi pada waktu ke-t

θ_0 : Nilai konstanta

ϕ_p : Koefisien parameter model AR orde ke-p

θ_q : Koefisien parameter model MA orde ke-q

a_t : Nilai residual pada waktu ke-t

$(1 - B)^d$: Pembedaan (*differencing*) pada periode d

d : Banyaknya *differencing* yang dilakukan

Salah satu kelemahan ARIMA adalah memerlukan periode data yang lama karena memerlukan data *in-sample* dan *out-sample* sebagai hasil pembagian dataset. Model dibentuk menggunakan data *in-sample*, sedangkan validasi model menggunakan data *out-sample*.

II.4. Uji Fungsi Korelasi

Uji fungsi korelasi yang digunakan antara lain adalah *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Penggunaan ACF umumnya untuk mengetahui tingkat korelasi dari hubungan linier dua variabel. Pada deret waktu, dua lag yang memiliki hubungan diketahui menggunakan uji ACF ini. Kovarian antara Y_t dan nilainya pada periode selanjutnya misalnya Y_{t+k} *autocovariance* pada lag ke-k yang didefinisikan sebagai berikut.

$$\gamma_k = Cov(Y_t + Y_{t+k}) = E[(Y_t - \mu)(Y_{t+k} - \mu)] \tag{4}$$

Sedikit berbeda dengan ACF, nilai observasi pada deret waktu dengan nilai observasi masa lalu yang memiliki nilai diukur menggunakan PACF, tetapi dengan mengontrol pengaruh observasi di antaranya. Autokorelasi parsial dari Y_t dan Y_{t-k} adalah korelasi antara Y_t dan Y_{t-k} dengan menyesuaikan atau memperhitungkan nilai dari $Y_{t-1}, Y_{t-2}, \dots, Y_{t-k+1}$. Plot ACF dan PACF memiliki sifat yang menjadi acuan untuk menentukan orde ARIMA pada Tabel 1[11].

Tabel 1. Sifat-Sifat ACF dan PACF pada model ARIMA



Proses	Sampel ACF	Sampel PACF
<i>White Noise</i>	Lag>0 tidak melewati garis batas interval	Lag>0 tidak melewati garis batas interval
AR(<i>p</i>)	Menurun hingga nol secara eksponensial	<i>Cut-off</i> pada lag ke- <i>p</i> berarti berada di atas garis interval maksimum sampai lag ke- <i>p</i> dan di bawah batas garis interval pada lag > <i>p</i>
MA(<i>q</i>)	<i>Cut-off</i> pada lag ke- <i>q</i> berarti berada di atas garis interval maksimum sampai lag ke- <i>p</i> dan di bawah batas garis interval pada lag > <i>q</i>	Menurun hingga nol secara eksponensial
ARMA(<i>p,q</i>)	Menurun hingga nol secara eksponensial	Menurun hingga nol secara eksponensial

II.5. Uji Diagnostik Model

Proses identifikasi model melibatkan pemilihan model-model kandidat yang selanjutnya akan diuji secara diagnostik untuk menentukan model prediktif yang paling tepat. Penelitian ini menerapkan uji Ljung-Box menggunakan hipotesis yang diberikan sebagai berikut [12]:

$$H_0: \hat{\rho}_k = 0 \quad (\text{Residual merupakan } white \text{ noise})$$

$$H_1: \hat{\rho}_k \neq 0 \quad (\text{Residual bukan } white \text{ noise})$$

dengan statistik uji:

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-K} \quad (5)$$

Keterangan:

K : Lag maksimum

N : Jumlah data

$\hat{\rho}_k$: Koefisien autokorelasi residual pada lag k

Jika $Q = \chi^2_{\alpha; df=k-p-q}$ atau *p-value* lebih dari α sehingga diambil keputusan tolak H_0 yang berarti bahwa autokorelasi residual tidak signifikan dan model layak digunakan. Selanjutnya, dilakukan uji asumsi residual berdistribusi normal menggunakan uji Kolmogorov-Smirnov dengan hipotesis uji sebagai [13], [14].

$$H_0: F(x) = F_0(x) \quad (\text{Residual berdistribusi normal})$$

$$H_1: F(x) \neq F_0(x) \quad (\text{Residual tidak berdistribusi normal})$$

Statistik uji yang digunakan yaitu:

$$D_{max} = \max |F(x) - F_0(x)| \quad (6)$$

Keterangan:

$F(x)$: distribusi frekuensi kumulatif teoritis

$F_0(x)$: distribusi frekuensi kumulatif observasi

Nilai D_{max} yang didapatkan melalui formula (6) dibandingkan dengan nilai D_{tabel} dari tabel Durbin-Watson pada taraf signifikansi (α) 0,05 atau 5% dan derajat bebas berupa ukuran sampel (n). Hipotesis diuji dengan kriteria H_0 diterima jika $D_{max} \leq D_{tabel}$ atau *p-value* > α , maka data terdistribusi normal.

II.6. Uji Evaluasi Model



Untuk evaluasi model pada penelitian ini menggunakan uji *Akaike’s Information Criterion* (AIC). AIC adalah metode yang umum digunakan dalam pemilihan model dengan performa terbaik berdasarkan metode *Maximum Likelihood Estimation* (MLE). Menurut metode ini, model terbaik pada suatu permasalahan adalah model dengan nilai AIC terkecil. Nilai AIC didapatkan dengan rumus sebagai berikut:

$$AIC = -2\log L(\hat{\theta}) + 2k \tag{7}$$

Keterangan:

$L(\hat{\theta})$: Fungsi *log-likelihood* untuk estimator parameter

k : Banyaknya parameter yang diestimasi

n : Banyaknya data

II.7. Uji Akurasi Peramalan

Setelah dilakukan evaluasi model, selanjutnya dilakukan uji keakuratan dari model terpilih. Pada penelitian ini uji keakuratan model dilakukan dengan metode *Mean Absolute Percentage Error* (MAPE). MAPE adalah uji yang menggambarkan baik tidaknya hasil peramalan. MAPE dapat dihitung menggunakan rumus berikut [15].

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|}{n} \times 100\% \tag{8}$$

Keterangan:

y_i : Nilai aktual

\hat{y}_i : Nilai peramalan

n : Jumlah data

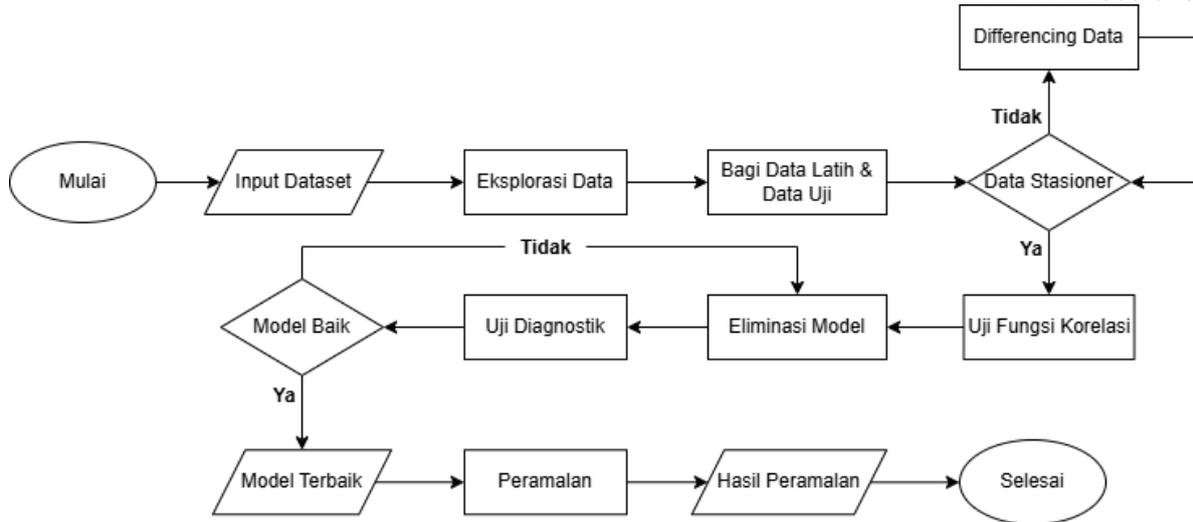
Jika nilai MAPE yang rendah, maka kemampuan model dalam meramalkan semakin baik. MAPE memiliki rentang nilai dalam pengukuran kemampuan bagaimana model tersebut meramalkan, rentang tersebut terdapat pada Tabel 2.

Tabel 2. Range Nilai MAPE

Range MAPE	Arti
<10%	Kemampuan Model Peramalan Sangat Baik
10 – 20%	Kemampuan Model Peramalan Baik
20 – 50%	Kemampuan Model Peramalan Layak
>50%	Kemampuan Model Peramalan Buruk

II.8. Flowchart

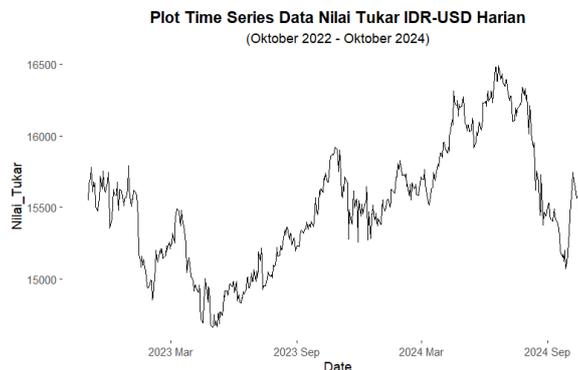
Alur pengerjaan penelitian ini dimulai dari mencari dataset. Dataset yang digunakan berasal dari *website Yahoo Finance* tentang nilai tukar rupiah ke dolar Amerika periode Oktober 2022 - Oktober 2024. Selanjutnya dataset diolah menggunakan *software* R Studio hingga mendapatkan hasil akhir model terbaik dan hasil dari ramalan menggunakan model terbaik yang sudah didapat. Gambaran alur pengerjaan ditunjukkan oleh Gambar 1.



Gambar 1. Alur Penelitian

III. HASIL DAN PEMBAHASAN

Berdasarkan Gambar 2, dapat diamati bahwa pergerakan kurs Rupiah terhadap Dollar Amerika Serikat (IDR/USD) selama periode Oktober 2022 hingga Oktober 2024 menunjukkan pola yang fluktuatif dan tidak mengikuti tren linier yang konsisten. Nilai tukar Rupiah sempat mengalami penguatan pada awal tahun 2023, namun kemudian menunjukkan pelemahan yang signifikan hingga pertengahan tahun 2024. Menjelang akhir periode pengamatan, tepatnya sekitar Oktober 2024, terlihat adanya indikasi pemulihan nilai tukar. Pola ini mencerminkan dinamika ekonomi yang kompleks, yang dipicu oleh berbagai faktor luar maupun dalam negeri, seperti regulasi moneter pemerintah Amerika Serikat, kondisi perekonomian global, kebijakan Bank Indonesia, serta stabilitas ekonomi domestik. *Insight* penting dari grafik ini adalah bahwa nilai tukar Rupiah sangat rentan terhadap gejolak ekonomi makro, sehingga memerlukan strategi prediktif dan kebijakan moneter yang adaptif untuk menjaga stabilitas kurs di masa depan.

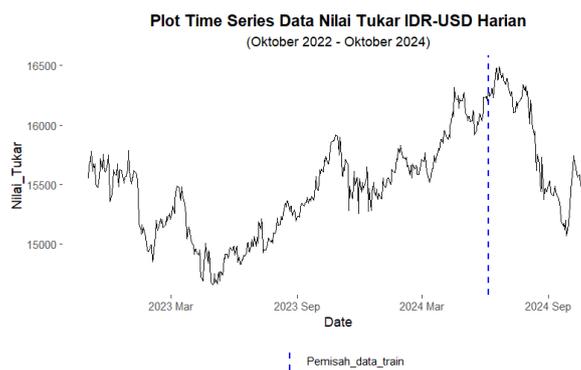


Gambar 2. Plot *time series* data nilai tukar rupiah ke dolar Amerika periode Oktober 2022 - Oktober 2024

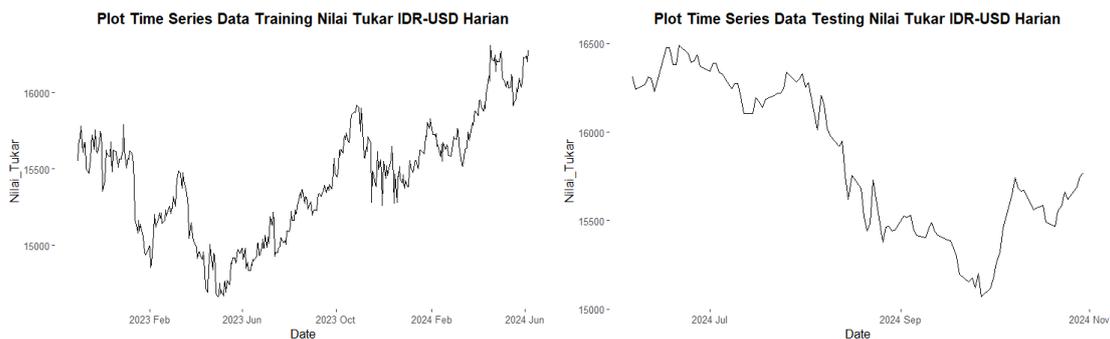
Pada Gambar 3a ditampilkan pemisahan data *time series* nilai tukar Rupiah terhadap USD menjadi dua segmen yaitu data latih dan data uji. Garis vertikal biru sebagai pemisah menunjukkan bahwa pembagian dilakukan secara kronologis, selaras dengan prinsip dasar dalam analisis deret waktu yang tidak memperkenankan pencampuran urutan data. Pada Gambar 3a garis putus-putus biru yang disebut "Pemisah_data_train" menunjukkan pembagian data. Garis merah menunjukkan batas antara data latih (*training data*) dan data uji (*testing data*). Dalam memprediksi nilai tukar IDR-USD, data sebelum garis merah atau pada Gambar 3b digunakan untuk melatih model (*training data*), dan data setelah garis biru atau pada Gambar 3c diterapkan guna menguji kemampuan prediktif model (*testing data*). Gambar 3b



menunjukkan bagian data latih yang berperan dalam membangun dan mengestimasi parameter model ARIMA, mencakup periode dari Oktober 2022 hingga pertengahan 2024. Sementara itu, Gambar 3c memperlihatkan data uji yang berperan dalam mengevaluasi kemampuan generalisasi model dalam meramalkan pergerakan nilai tukar setelah periode pelatihan, yaitu dari pertengahan hingga akhir tahun 2024. Insight penting dari visualisasi ini adalah bahwa model dievaluasi secara *fair* karena prediksi dilakukan pada data yang belum pernah dikenali oleh model sebelumnya. Selain itu, adanya fluktuasi tajam pada data uji menegaskan pentingnya pemilihan model yang mampu menangkap dinamika kompleks dan volatilitas pada data deret waktu keuangan. Strategi pembagian data ini juga mendukung praktik validasi model yang baik untuk menghindari *overfitting* serta meningkatkan keandalan hasil peramalan dalam konteks ekonomi riil.



Gambar 3a. Plot *time series* pembagian data latih dan data uji



Gambar 3b. Plot data latih

Gambar 3c. Plot data uji

Gambar 4 menunjukkan plot *Autocorrelation Function* (ACF) terhadap data deret waktu kurs Rupiah terhadap USD pada data latih. Berdasarkan grafik tersebut, terlihat bahwa nilai autokorelasi pada banyak lag berada jauh di luar batas signifikansi (ditandai oleh garis putus-putus biru), yang menunjukkan bahwa data memiliki autokorelasi yang sangat kuat dan tidak menurun secara spesifik. Hal ini menandakan jika data yang digunakan *non-stasioner*, karena salah satu ciri dari deret waktu yang tidak stasioner adalah adanya korelasi yang tinggi antar nilai observasi pada lag yang berjauhan [16]. Dalam konteks model ARIMA, pengujian stasioneritas merupakan tahap awal yang krusial karena model ARIMA mengasumsikan bahwa data harus bersifat stasioner secara mean dan variansi untuk menghasilkan estimasi parameter yang valid [17]. Oleh karena itu, hasil dari plot ACF ini menjadi dasar untuk melakukan proses *differencing* (penyurutan) pada data, yaitu tahap integrasi (I) dalam model ARIMA, guna menghilangkan tren dan membuat data menjadi stasioner. Ini merupakan prosedur yang



umum dilakukan dalam pemodelan ARIMA untuk mentransformasikan data non-stasioner menjadi stasioner sebelum menentukan nilai parameter AR (*Autoregressive*) dan MA (*Moving Average*).

Berdasarkan pengujian stasioneritas dengan metode ADF (*Augmented Dickey-Fuller*), didapatkan nilai *p-value* yang lebih tinggi dari tingkat signifikansi, yaitu 5% (0.05), sehingga dapat ditarik kesimpulan bahwa data tidak bersifat stasioner. Ketidakstasioneran data menunjukkan bahwa terdapat tren atau pola yang berulang secara musiman yang signifikan dalam deret waktu tersebut, yang dapat mempengaruhi hasil analisis selanjutnya. Hal ini penting untuk diperhatikan karena model deret waktu seperti ARIMA membutuhkan data yang stasioner untuk menghasilkan prediksi yang akurat.

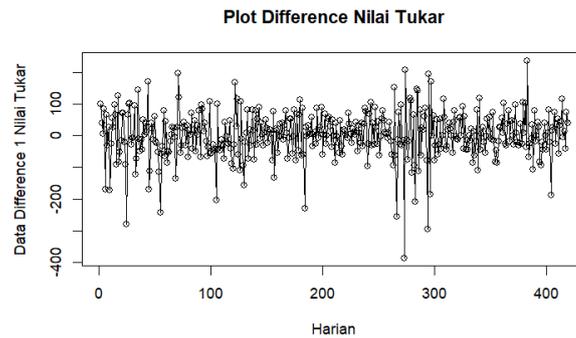
Plot ACF (*Autocorrelation Function*) pada Gambar 4 menunjukkan bahwa nilai autokorelasi masih signifikan pada beberapa lag awal dan perlahan menurun seiring bertambahnya lag. Hal ini menegaskan bahwa data menunjukkan adanya ketergantungan antar waktu yang mengindikasikan non-stasioneritas. Secara visual, pola ini memperkuat hasil uji ADF, di mana data memiliki elemen tren yang kuat dan memerlukan transformasi lebih lanjut, seperti diferensiasi, untuk mencapai stasioneritas.



Gambar 4. Plot ACF Pengujian Stasioneritas

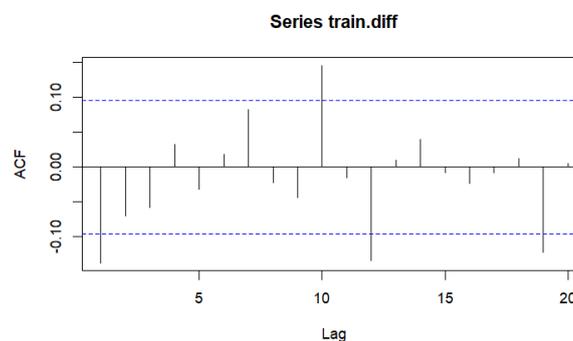
Setelah dilakukan tahap *differencing* satu kali yang ada pada Gambar 5, data nilai tukar menunjukkan perubahan yang signifikan dibandingkan sebelum transformasi. Proses *differencing* bertujuan untuk menghapus tren atau pola musiman pada data deret waktu agar data menjadi stasioner. Berdasarkan plot hasil *differencing*, fluktuasi data menjadi lebih teratur dan mendekati distribusi yang stasioner, di mana rata-rata fluktuasi data bergerak di sekitar nol. Ini menunjukkan bahwa tren jangka panjang dalam data telah berhasil dihilangkan.

Gambar 5 menampilkan plot deret waktu kurs Rupiah terhadap Dollar Amerika Serikat setelah melewati proses *differencing* sebanyak satu kali. Tujuan dari *differencing* adalah untuk menghapus tren dan menjadikan data bersifat stasioner. Setelah dilakukan *differencing*, pola fluktuasi nilai tukar terlihat lebih stabil di sekitar garis tengah (mean), tanpa adanya tren naik atau turun yang jelas, serta variansi yang relatif konstan. Ini merupakan indikasi kuat bahwa data telah mencapai sifat stasioner secara mean dan variansi. Proses *differencing* ini sesuai dengan konsep dalam pemodelan ARIMA, di mana huruf “I” (*Integrated*) merujuk pada banyaknya diferensiasi yang diperlukan untuk membuat data stasioner. Jika data asli bersifat non-stasioner, maka dilakukan transformasi dengan *first differencing* ($d = 1$). Keberhasilan *differencing* ini juga nantinya dikonfirmasi melalui plot ACF dan PACF dari data hasil *differencing* [16]. Stasioneritas merupakan syarat utama dalam pemodelan ARIMA, karena model ini mengandalkan kestabilan struktur statistik data sepanjang waktu untuk melakukan peramalan yang akurat [17]. Dengan memastikan bahwa data telah stasioner, model ARIMA yang dibangun diharapkan memberikan estimasi parameter yang valid dan performa peramalan yang baik.



Gambar 5. Plot data setelah dilakukan *differencing* satu kali

Data menunjukkan perubahan signifikan dalam hal stasioneritas. Hal ini didukung oleh hasil uji ADF setelah *differencing*, di mana *p-value* yang diperoleh adalah 0.01, yang lebih kecil dari nilai signifikansi 5%. Dengan demikian, dapat ditarik kesimpulan bahwa data sudah stasioner setelah dilakukan *differencing* satu kali. Pada Gambar 6. ditampilkan plot ACF (*Autocorrelation Function*) dari data setelah *differencing*. Plot ini menunjukkan bahwa sebagian besar nilai autokorelasi sudah berada dalam batas signifikan yang ditunjukkan oleh garis putus-putus biru. Ini menunjukkan bahwa komponen tren atau ketergantungan antar waktu yang ada pada data sebelumnya telah berhasil dihilangkan. Autokorelasi yang signifikan hanya terlihat pada lag-lag awal, yang merupakan ciri khas dari data yang sudah mengalami proses *differencing*. Sebelumnya, data menunjukkan karakteristik non-stasioner, yang diindikasikan oleh *p-value* yang lebih tinggi dari 0.05 pada uji ADF sebelum *differencing*. Selain itu, plot ACF pada data sebelum transformasi menunjukkan adanya autokorelasi yang substansial pada beberapa lag awal, yang menandakan adanya pola ketergantungan antar waktu. Namun, setelah dilakukan *differencing*, pola tersebut tidak lagi terlihat, sehingga data menjadi lebih sesuai untuk dimodelkan menggunakan metode deret waktu seperti ARIMA.

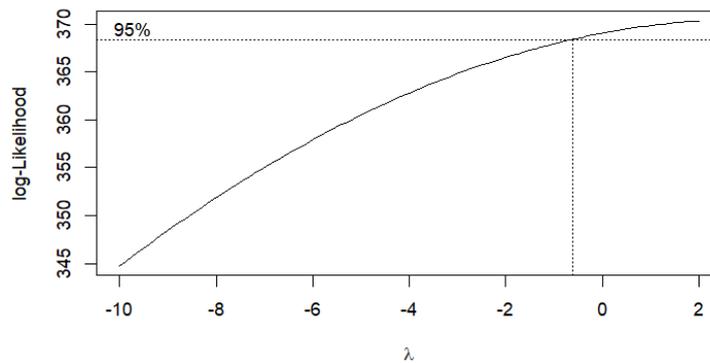


Gambar 6. Plot ACF data setelah dilakukan *differencing* satu kali

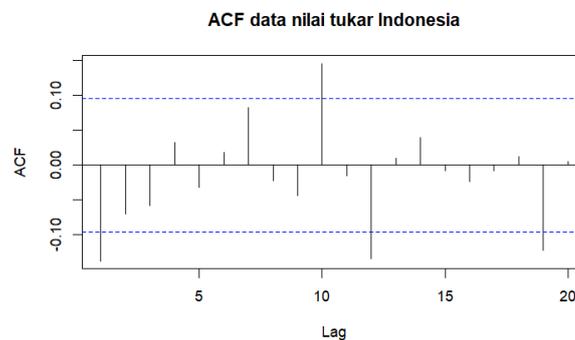
Gambar 7. menunjukkan hasil uji stasioneritas ragam dengan transformasi Box-Cox, dengan nilai λ optimal yang ditemukan sebesar 2. Transformasi Box-Cox digunakan untuk menstabilkan varians data yang heteroskedastik. Dengan kata lain, tujuan utama dari uji ini adalah untuk mengatasi permasalahan varians yang berubah-ubah seiring waktu, sehingga model deret waktu dapat dibangun dengan asumsi varians yang konstan (*homoskedastic*). Pada plot *log-likelihood* terhadap nilai λ , terlihat bahwa puncak kurva berada di sekitar nilai $\lambda = 2$, yang merupakan nilai optimal untuk melakukan transformasi. Pada area ini, nilai *likelihood* mencapai nilai tertinggi, yang berarti bahwa transformasi pada nilai λ tersebut dapat membuat varians data menjadi lebih stabil dan mendekati distribusi normal.



Selanjutnya, transformasi Box-Cox dengan nilai $\lambda = 2$ dapat diterapkan pada data untuk melihat pengaruhnya terhadap stasioneritas ragam.



Gambar 7. Plot uji stasioneritas ragam dengan uji Box-cox

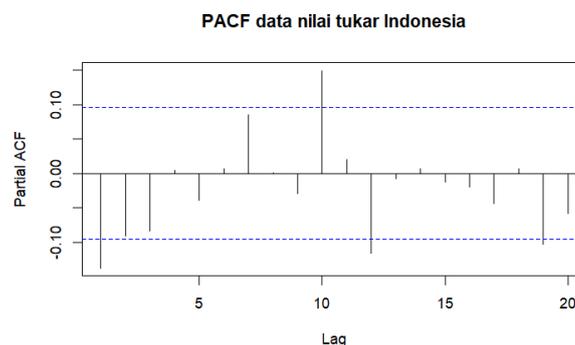


Gambar 8. Plot ACF

Gambar 8. yang menampilkan plot ACF (*Autocorrelation Function*) dari data nilai tukar Indonesia, menunjukkan bahwa terdapat *cuts-off* yang signifikan pada lag 1 dan lag 2. Hal ini mengindikasikan bahwa komponen *moving average* (MA) dalam model deret waktu dapat diidentifikasi menggunakan ordo 1 dan 2. Dengan kata lain, model MA (1) dan MA (2) dapat menjadi kandidat dalam pemodelan deret waktu untuk menangkap pola autokorelasi dalam data tersebut. Interpretasi *cut-off* pada lag 1 dan 2 berarti bahwa nilai observasi saat ini dipengaruhi oleh nilai residual dari 1 periode dan 2 periode sebelumnya. Keberadaan autokorelasi signifikan pada lag-lag ini mendukung penggunaan ordo 1 dan 2 untuk komponen MA.

Gambar 9. menampilkan plot PACF (*Partial Autocorrelation Function*) dari data nilai tukar Indonesia. Berdasarkan plot tersebut, terlihat adanya *cut-off* yang signifikan pada lag 1 dan 2. Ini menunjukkan bahwa model *autoregressive* (AR) dengan ordo 1 dan 2 dapat digunakan untuk menangkap pola ketergantungan parsial dalam data. *Cut-off* pada lag 1 dan 2 berarti bahwa nilai observasi saat ini memiliki hubungan langsung dengan nilai observasi pada 1 dan 2 periode sebelumnya. Ini penting dalam menentukan struktur AR dalam model ARIMA, di mana ordo AR menunjukkan seberapa jauh pengaruh nilai sebelumnya dalam memprediksi nilai sekarang. Dengan demikian, hasil dari plot PACF ini menyarankan bahwa model ARIMA yang cocok untuk data nilai tukar ini kemungkinan besar memerlukan komponen AR dengan ordo 1 dan 2. Selanjutnya, model ARIMA (p, d, q) dengan p = 1 dan 2 bisa dieksplorasi lebih lanjut untuk melihat kombinasi yang paling sesuai dengan data. Dari plot ACF dan PACF, ordo ARIMA yang akan dipilih untuk pemodelan yaitu orde (1,1,1) dan (2,1,2).

Selain itu, Gambar 9. juga menunjukkan *Partial Autocorrelation Function* (PACF) dari data nilai tukar Indonesia setelah dilakukan *differencing*. Grafik ini digunakan untuk mengidentifikasi order dari komponen *Autoregressive* (AR) dalam model ARIMA. Dalam plot PACF tersebut, terlihat bahwa lag ke-1 dan lag ke-10 menunjukkan *spike* yang signifikan (melewati batas signifikansi 95% yang ditunjukkan oleh garis biru putus-putus). Ini mengindikasikan bahwa nilai tukar saat ini memiliki hubungan parsial yang signifikan dengan nilai tukar satu hari dan sepuluh hari sebelumnya, setelah mengontrol pengaruh lag-lag sebelumnya. Oleh karena itu, nilai AR (p) yang layak dipertimbangkan dalam pemodelan ARIMA adalah $p = 1$ atau $p = 10$, meskipun $p = 1$ umumnya menjadi pilihan awal yang lebih sederhana [16]. PACF sangat penting karena membantu dalam menghindari *overfitting* model ARIMA. Sementara ACF digunakan untuk menentukan order MA (*Moving Average*), PACF lebih tepat untuk menentukan order AR. Kombinasi analisis ACF dan PACF memberikan dasar kuat dalam pemilihan parameter terbaik (p, d, q) untuk model ARIMA [17].



Gambar 9. Plot PACF

Berdasarkan hasil uji signifikansi berbagai model ARIMA, terdapat cukup bukti untuk menyatakan bahwa ARIMA(2,1,2) merupakan model yang sangat signifikan. Hal ini ditunjukkan oleh nilai p -value yang sangat kecil (di bawah $2.2e-16$) untuk seluruh parameternya, yaitu ar_1 dan ma_1 , yang mencerminkan tingkat signifikansi yang tinggi dan kepercayaan yang kuat terhadap kontribusi masing-masing parameter dalam model. Tabel 3 menyajikan hasil estimasi parameter dari dua model ARIMA, yaitu ARIMA(1,1,1) dan ARIMA(2,1,2), yang berfungsi untuk memodelkan data kurs Rupiah terhadap USD. Seluruh parameter pada kedua model menunjukkan nilai p -value kurang dari 0,05, yang berarti signifikan secara statistik pada tingkat kepercayaan 95%. Namun demikian, model ARIMA(2,1,2) memiliki keunggulan karena seluruh parameter *autoregressive* (AR) dan *moving average* (MA) tidak hanya signifikan tetapi juga menunjukkan pengaruh yang kuat. Misalnya, parameter ar_1 bernilai 1,4472 dengan p -value $< 2.2e-16$, dan ma_1 sebesar -1,6069 juga sangat signifikan. Hal ini mengindikasikan bahwa model ini mampu menangkap pola ketergantungan nilai tukar terhadap nilai masa lalu dan gangguan acak secara lebih kompleks dibandingkan ARIMA(1,1,1), yang hanya memuat satu lag AR dan satu lag MA dengan signifikansi lebih rendah.

Menurut Tsay (2010), model yang memiliki parameter signifikan secara statistik tanpa *overfitting* dikategorikan sebagai model *parsimonious* yang baik untuk peramalan [18]. Selain itu, Shumway dan Stoffer (2025) juga menyatakan bahwa pemilihan model yang tepat dalam analisis deret waktu harus mempertimbangkan signifikansi parameter selain nilai AIC atau BIC [19]. Oleh karena itu, berdasarkan hasil estimasi ini dan merujuk pada teori *time series* yang relevan, model ARIMA(2,1,2) dapat dianggap sebagai model yang lebih representatif untuk menggambarkan dinamika kurs Rupiah terhadap USD.



Model ini dapat memberikan dasar yang lebih kuat bagi pengambilan keputusan ekonomi, khususnya dalam kebijakan moneter atau intervensi pasar valuta asing.

Tabel 3. Ringkasan Statistik Model

Model	Variabel	Estimate	Std. Error	z-value	Pr(> z)	Signifikansi
ARIMA	ar1	0.3875	0.1654	2.3425	0.0191	.*
(1,1,1)	ma1	-0.5526	0.1473	-3.7504	0.0001	***
	ar1	1.4472	0.1664	8.6968	< 2.2e-16	***
ARIMA	ar2	-0.6319	0.1124	-5.6195	1.916e-08	***
(2,1,2)	ma1	-1.6069	0.1558	-10.3125	< 2.2e-16	***
	ma2	0.7654	0.1030	7.4289	1.095e-13	***

Menurut nilai AIC pada Tabel 4, model dengan nilai AIC terendah adalah model 2 dengan nilai 4781.886, yang merupakan model ARIMA(2,1,2). Meskipun fungsi `auto.arima` di R merekomendasikan model 1 (ARIMA(1,1,1)) dengan nilai AIC 4781.998, model 2 (ARIMA(2,1,2)) memiliki nilai AIC terendah dan signifikansi yang paling besar. Oleh karena itu, model ARIMA(2,1,2) terpilih sebagai model terbaik karena menunjukkan nilai AIC terendah. Pengujian ulang dilakukan agar *overfitting* model ARIMA(2,1,2) (model 2), beberapa model alternatif dicoba, yaitu model 2a (ARIMA(2,1,1)), 2b (ARIMA(3,1,1)), 2c (ARIMA(1,1,2)), 2d (ARIMA(1,1,0)), dan 2e (ARIMA(2,1,0)).

Tabel 4. Nilai AIC tiap Model

Nama model	AIC
Model 1	4781.998
Model 2	4781.886

Berdasarkan Tabel AIC yang ditampilkan, pemilihan model ARIMA yang optimal dilakukan dengan mempertimbangkan nilai *Akaike Information Criterion* (AIC) yang paling rendah. Nilai AIC merupakan salah satu metode paling umum yang digunakan dalam pemilihan model *time series* karena mengukur keseimbangan antara kebaikan model (*goodness of fit*) dan kompleksitas model (jumlah parameter)[19]. Dari tabel tersebut, terlihat bahwa Model 2 memiliki nilai AIC paling kecil yaitu sebesar 4781.886, dibandingkan dengan model-model alternatif seperti Model 2a sampai Model 2e. Oleh karena itu, Model 2 terpilih sebagai model terbaik untuk memprediksi nilai tukar Rupiah terhadap USD, karena secara statistik memberikan keseimbangan optimal antara akurasi dan efisiensi parameter. Nilai AIC yang lebih rendah mengindikasikan bahwa model tersebut memberikan estimasi yang lebih baik terhadap data dengan risiko *overfitting* yang lebih rendah dibandingkan model lainnya. Dengan demikian, pemilihan Model 2 (yang dalam penelitian ini adalah ARIMA(2,1,2)) didasarkan atas pendekatan yang kuat secara teoritis dan empiris dalam kerangka pemodelan *time series* [18].

Tabel 5. Nilai AIC *overfitting* model 2 Arima(2,1,2)



Nama Model	AIC
Model 2	4781.886
Model 2a	4783.674
Model 2b	4784.812
Model 2c	4783.748
Model 2d	4785.184
Model 2e	4783.749

Gambar 10. menampilkan empat jenis plot residual untuk model ARIMA (2,1,2) (Model 2), yang digunakan untuk memvalidasi kualitas model dan memastikan bahwa asumsi-asumsi utama dipenuhi. Plot Q-Q Normal menunjukkan sebagian besar residual mengikuti garis diagonal, menunjukkan distribusi yang hampir normal, meskipun ada beberapa deviasi di ekor. Residual vs. Order menunjukkan nilai-nilai residual menyebar secara acak di sekitar garis nol tanpa membentuk pola tertentu, yang mengindikasikan tidak adanya korelasi yang berarti antar data. Plot ACF menunjukkan sebagian besar nilai autokorelasi residual berada dalam batas signifikan yang mengindikasikan bahwa tidak ada autokorelasi yang kuat. Plot terakhir yaitu plot PACF menunjukkan hampir semua nilai autokorelasi residual berada dalam batas signifikan, menunjukkan bahwa tidak ada autokorelasi parsial yang signifikan. Secara keseluruhan, keempat plot ini menandakan bahwa model ARIMA (2,1,2) beroperasi dengan baik, dengan residual yang hampir normal, acak, dan tidak menunjukkan korelasi yang signifikan. Hal ini mengindikasikan bahwa model ini cukup andal dalam memodelkan data.

Dilakukan beberapa uji formal untuk menguji sisaan.

1. Sisaan menyebar normal

Uji sebaran normal sisaan dilakukan dengan uji Shapiro-Wilk. Adapun hipotesis yang digunakan adalah sebagai berikut:

$$H_0: \text{Sisaan mengikuti sebaran normal}$$

$$H_1: \text{Sisaan tidak mengikuti sebaran normal}$$

Berdasarkan hasil uji Saphiro-Wilk, dihasilkan nilai *p-value* sebesar 0.06206 di mana nilai tersebut lebih besar dari *alpha* 0.05. Sehingga dari hasil tersebut dapat diambil kesimpulan pada taraf signifikan 5%, cukup bukti untuk menyatakan bahwa sisaan mengikuti sebaran normal.

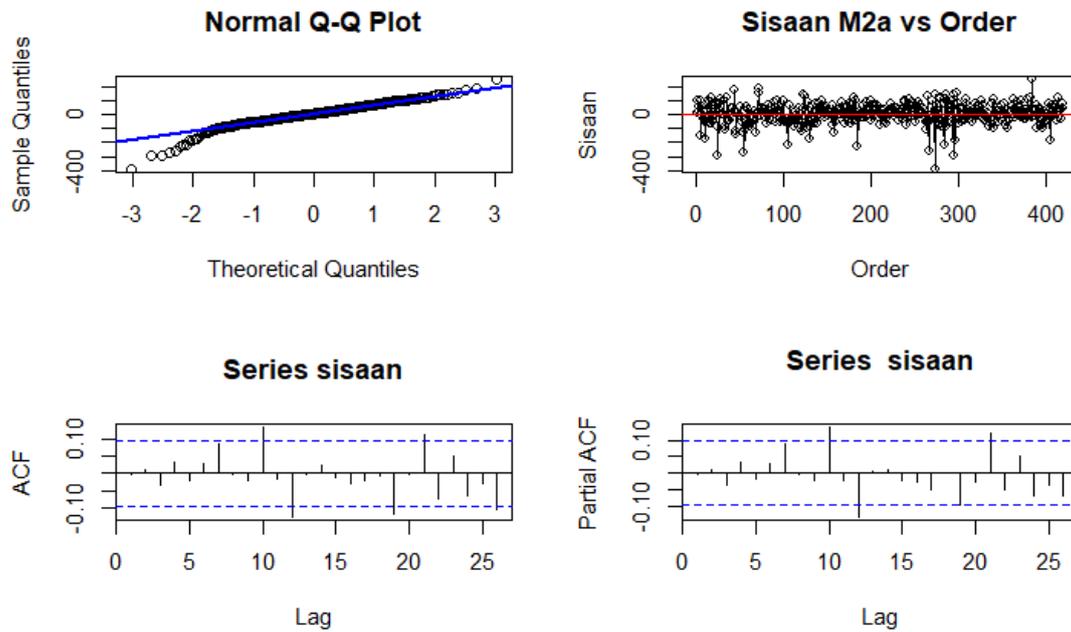
2. Sisaan saling bebas/tidak ada korelasi

Uji korelasi dilakukan dengan menggunakan uji Box-Ljung. Adapun hipotesis yang digunakan adalah sebagai berikut:

$$H_0: \text{Tidak ada autokorelasi}$$

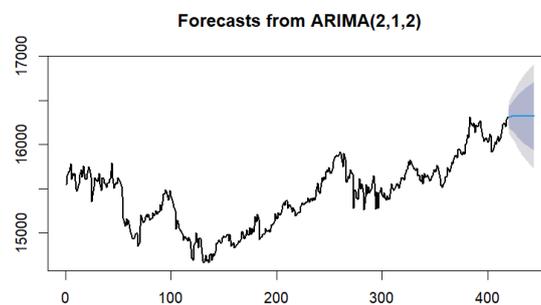
$$H_1: \text{Ada autokorelasi}$$

Dari pengujian Box-Ljung, didapat hasil *p-value* sebesar 0.9883 yang mana nilai lebih besar dari *alpha* 0.05. Hasil ini memiliki cukup bukti untuk menyatakan bahwa pada taraf signifikan 5% sisaan tidak berkorelasi (saling bebas).



Gambar 10. Plot Uji Sisaan

Plot pada Gambar 11. dan Tabel 6. di atas menunjukkan peramalan 5 hari menggunakan model ARIMA(2,1,2) dengan *drift* pada data deret waktu. Peramalan ditampilkan di ujung kanan grafik, dengan area bayangan abu-abu di sekitar garis prediksi menunjukkan ketidakpastian. Hasil evaluasi akurasi menunjukkan nilai MAPE (*Mean Absolute Percentage Error*) sebesar 26%, yang menunjukkan bahwa model ini memberikan prediksi dengan akurasi yang cukup dan moderat, karena nilai MAPE di atas 10%. Singkatnya, model ARIMA ini menghasilkan hasil peramalan yang dapat diperbaiki lebih lanjut untuk peramalan data nilai tukar yang lebih akurat.



Gambar 11. Plot peramalan/forecasting data nilai tukar rupiah – dolar Amerika menggunakan model Arima(2,1,2)

Tabel 6. Perbandingan Nilai Tukar Asli dengan Hasil Prediksi Model.

Tanggal	Data Asli	Prediksi Model
06-06-2024	Rp. 16.315,0	Rp. 16.311,97
07-06-2024	Rp. 16.241,7	Rp. 16.312,16
08-06-2024	Rp. 16.270,0	Rp. 16.314,38



09-06-2024	Rp. 16.312,0	Rp. 16.317,39
10-06-2024	Rp. 16.305,4	Rp. 16.320,18

IV. KESIMPULAN

Berdasarkan penelitian yang sudah dilakukan mengenai nilai tukar Rupiah terhadap Dollar menggunakan ARIMA, dinyatakan bahwa hasil peramalan menghasilkan MAPE sebesar 26% yang menunjukkan bahwa model cukup baik, namun masih diperlukan pengembangan model lebih lanjut. Model terbaik dalam penelitian ini yaitu ARIMA(2,1,2) dengan nilai AIC sebesar 4781.886. ARIMA(2,1,2) memenuhi uji diagnostik dengan residual bersifat *white noise*, karena residual berdistribusi normal dan sisaan tidak berkorelasi (saling bebas).

UCAPAN TERIMA KASIH

Terima kasih kepada Tim SENADA atas waktu dan tenaganya dalam menyusun *template* artikel ini, serta kepada semua pihak yang telah membantu dan mendukung proses penulisan, baik secara langsung maupun tidak langsung. Semoga segala kebaikan dan kerja sama yang diberikan menjadi amal yang bermanfaat.

REFERENSI

- [1] G. Ardesfira, H. F. Zedha, I. Fazana, J. Rahmadhiyanti, S. Rahima, and S. Anwar, “Peramalan Nilai Tukar Rupiah Terhadap Dollar Amerika Dengan Menggunakan Metode Autoregressive Integrated Moving Average (Arima),” *Jambura J. Probab. Stat.*, vol. 3, no. 2, pp. 71–84, 2022, doi: 10.34312/jjps.v3i2.15469.
- [2] I. S. Saerang, V. N. Untu, J. Manajemen, and F. Ekonomi, “14. Jurnal+Kerenhapukh+Irianty+Lobo,” vol. 12, no. 03, pp. 516–527, 2024.
- [3] H. Sulastri, G. S. Anwar, and E. N. F. Dewi, “Peramalan Stok Barang Percetakan dan ATK Menggunakan Single Moving Average,” *J. Rekayasa Teknol. Inf.*, vol. 7, no. 1, p. 59, 2023, doi: 10.30872/jurti.v7i1.11876.
- [4] I. F. Amri, L. Puspitasari, D. Priambodo, R. D. Azzahrani, and M. Al Haris, “Estimasi Risiko Pada Saham PT . Gojek Tokopedia Tbk dan Expected Shortfall Menggunakan ARIMA-GARCH Model Estimasi Risiko Pada Saham PT . Gojek Tokopedia Tbk dan Expected Shortfall Menggunakan ARIMA-GARCH Model,” 2024.
- [5] R. A. Prasetyowati, “Model Perilaku Kompetisi Perbankan Syariah: Pembuktian Empiris Industri Bank Umum Syariah Indonesia Dan Malaysia,” UIN Syarif Hidayatullah Jakarta, 2020. [Online]. Available: <https://repository.uinjkt.ac.id/dspace/handle/123456789/56468>
- [6] T. J. Moskowitz, Y. H. Ooi, and L. H. Pedersen, “Time series momentum,” *J. financ. econ.*, vol. 104, no. 2, pp. 228–250, 2012, doi: 10.1016/j.jfineco.2011.11.003.
- [7] M. Huda, R. N. N. Azizah, and A. N. Setyana, “Implementasi Metode Arma Dalam Peramalan Inflasi Provinsi Banten Periode Tahun 2018 Sampai Tahun 2023,” *J. Bayesian J. Ilm. Stat. dan Ekon.*, vol. 3, no. 2, pp. 210–221, 2023.
- [8] F. Z. Ulya, A. R. Wijaya, and P. L. Puspita, “Peramalan Harga Cabai dan Bawang di Pasar Tradisional Purwokerto dengan Model Autoregressive Integrated Moving Average (ARIMA),” *Semin. Nas. Off. Stat.*, vol. 2023, no. 1, pp. 757–766, 2023, doi: 10.34123/semnasoffstat.v2023i1.1794.



- [9] Queenty Dhea Haura Br Sitepu, Sutarman Sutarman, and Machrani Adi Putri Siregar, “Metode Autoregressive Integrated Moving Average (Arima) dalam Memprediksi Jumlah Penumpang Kereta Api Kota Binjai,” *J. Arjuna Publ. Ilmu Pendidikan, Bhs. dan Mat.*, vol. 2, no. 2, pp. 69–85, 2024, doi: 10.61132/arjuna.v2i2.621.
- [10] K. Huda, C. E. Wibowo, and V. Gunawan, “Implementation of time series forecasting with Box Jenkins ARIMA method on wood production of Indonesian forests,” in *11th International Seminar on New Paradigm and Innovation on Natural Sciences and Its Application (11th ISNPINSA)*, 2023, p. 2738.
- [11] H. A. Khoiri, *Analisis Deret Waktu Univariat*, no. 85. 2022. [Online]. Available: https://www.google.co.id/books/edition/Analisis_Deret_Waktu_Univariat_Linier/XGimEAAAQBAJ?hl=id&gbpv=1&dq=deret+waktu&printsec=frontcover
- [12] S. Halim *et al.*, “Prediksi Jumlah Wisatawan Mancanegara Ke Indonesia Berdasarkan Kebangsaan Menggunakan SARIMA,” 2022.
- [13] R. Yoel, R. Y. Wawo, D. T. Salaki, H. Andrea, H. Komalig, and D. Hatidja, “Perbandingan Metode Triple Exponential Smoothing Additive dan Additive Parameter Damped untuk Peramalan Indeks Harga Konsumen Perbandingan Metode Triple Exponential Smoothing Additive dan Additive Parameter Damped untuk Peramalan Indeks Harga Konsumen,” vol. 13, no. 1, pp. 77–83, 2025.
- [14] N. Manabung *et al.*, “Peramalan Banyaknya Pasien yang Berobat di Puskesmas Bengkol dengan Menggunakan Metode ARIMA Forecasting the Number of Patients Seeking Treatment at the Bengkol Health Center Using the ARIMA Method,” vol. 9, no. 1, pp. 11–19, 2024.
- [15] M. M. Azman, “Analisa perbandingan nilai akurasi moving average dan exponential smoothing untuk sistem peramalan pendapatan pada perusahaan XYZ,” *J. Sist. dan Inform.*, vol. 13, no. 2, pp. 36–45, 2019.
- [16] G. T. Wilson, “Time Series Analysis: Forecasting and Control, 5th Edition, by George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung, 2015. Published by John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712. ISBN: 978-1-118-67502-1,” *J. Time Ser. Anal.*, vol. 37, no. 5, pp. 709–711, 2016, doi: 10.1111/jtsa.12194.
- [17] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*. OTexts, 2018.
- [18] R. S. Tsay, *Analysis of Financial Time Series*. John Wiley & Sons, Inc., 2010.
- [19] D. S. S. Robert H. Shumway, *Time Series Analysis and Its Applications*. Switzerland: Springer, 2025.