

PENERAPAN MODEL AUTOREGRESSIVE FRACTIONALLY INTEGRATED MOVING AVERAGE DALAM MERAMALKAN NILAI TUKAR RUPIAH TERHADAP US DOLLAR (USD/IDR)

Ayu Fajar Rusadi¹, Yeni Rahkmawati^{2*}, Fitri Handayani³

^{1,2} Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lambung Mangkurat

³ Badan Pusat Statistik Provinsi Kalimantan Selatan

*e-mail: yeni.rahmawati@ulm.ac.id

DOI: [10.14710/j.gauss.14.2.535-546](https://doi.org/10.14710/j.gauss.14.2.535-546)

Article Info:

Received: 2025-05-20

Accepted: 2025-12-03

Available Online: 2025-12-10

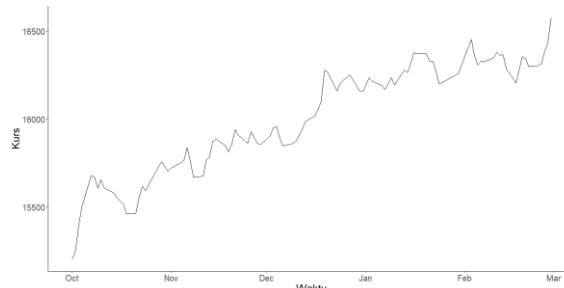
Keywords:

Time Series Analysis; Long Memory; ARFIMA; Exchange Rate of Rupiah; US Dollar

Abstract: The Autoregressive Fractionally Integrated Moving Average (ARFIMA) model is employed to analyze data exhibiting long memory characteristics through the use of a fractional differencing coefficient. This study differs from previous research, as no existing studies have been found that discuss the forecasting of the rupiah exchange rate against the United States Dollar (USD) using recent data and the ARFIMA model. This study examines the daily exchange rate of the rupiah against the United States Dollar (USD/IDR) from January 2023 to March 2025, totaling 535 observations. The results indicate a general weakening trend of the Rupiah during this period. The Hurst exponent ($H = 0.837162$), which falls within the range $0.5 < H < 1$, confirms the presence of long memory behavior in the data. The best fitting ARFIMA specification is identified as ARFIMA(3,0.337162,0). Instead of presenting the formal mathematical expression, the model can be interpreted as capturing both short-term fluctuations and persistent long-term dependencies in the exchange rate movements. The forecasting results indicate a potential appreciation of the Rupiah against the USD in the future. When compared with the actual data, the Rupiah instead experienced depreciation. This discrepancy provides important insights into exchange rate dynamics and suggests that there are other factors outside the model influencing the movement of the Rupiah, resulting in actual values that differ from the forecasted outcomes.

1. PENDAHULUAN

Nilai tukar atau sering disebut sebagai kurs merupakan representasi dari perubahan atau konversi suatu harga mata uang yang ditentukan melalui dinamika penawaran dan permintaan terhadap mata uang sebuah negara (Ardesfira, et al., 2022). Penggunaan mata uang *US Dollar* (USD) sebagai transaksi dalam perdagangan internasional menyebabkan adanya pertukaran nilai tukar rupiah yang berfluktuasi seiring berjalannya waktu.



Gambar 1. Data Nilai Tukar Rupiah terhadap USD Periode Oktober 2024 - Februari 2025

Berdasarkan Gambar 1, pergerakan pola data nilai tukar rupiah terhadap *US Dollar* (USD/IDR) cenderung menunjukkan kenaikan (pelemahan) atau memiliki pola tren naik, hal ini mengidentifikasi bahwa nilai rupiah secara konsisten terus melemah. Pelemahan nilai tukar dapat memicu tingkat inflasi dalam negeri, kondisi ini tidak hanya berdampak pada individu tetapi juga dapat memengaruhi stabilitas ekonomi secara keseluruhan. Faustina (2023) menjelaskan bahwa penguatan nilai tukar rupiah dapat membawa dampak positif bagi perekonomian.

Nilai tukar menunjukkan karakteristik *long memory*, yakni ketergantungan jangka panjang terhadap nilai-nilai historis. Pola ini terlihat baik pada negara-negara berkembang, termasuk Indonesia, maupun pada sistem nilai tukar utama di era euro (Asif & Frömmel, 2022). Salah satu metode analisis statistik yang efektif untuk memodelkan dan meramalkan fluktuasi nilai tukar rupiah terhadap *US Dollar* (USD/IDR) ialah model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA). Dalam pemodelan ARFIMA, terdapat sebuah karakteristik data yang harus terpenuhi yaitu sifat memori jangka panjang (*long memory*). Model ARFIMA merupakan perluasan dari model ARIMA yang digunakan khusus untuk menangani data bersifat *long memory*. *Long memory* merupakan sebuah proses yang menunjukkan ketergantungan memori jangka panjang, dengan pengaruh observasi dari masa lalu yang bertahan lebih lama sehingga akan berpengaruh terhadap hasil peramalan.

Penelitian terkait penggunaan model ARFIMA sebelumnya pernah dibahas oleh Melani, et al. (2022), Winanti, et al. (2023) dan Imani, et al. (2023). Dari ketiga penelitian tersebut, pemodelan ARFIMA digunakan untuk meramalkan data keuangan seperti Indeks Harga Perdagangan dan beberapa indikator pasar lainnya. Hasil penelitian tersebut menunjukkan bahwa model ARFIMA efektif dalam menangkap sifat *long memory* pada data keuangan. Namun demikian, belum ada penelitian yang secara khusus menerapkan model ARFIMA untuk data nilai tukar rupiah terhadap *US Dollar* dengan menggunakan data terbaru periode 2023–2025 yang memiliki dinamika berbeda pasca-pandemi. Oleh karena itu, penelitian ini dilakukan untuk mengisi kekosongan tersebut dengan menentukan model ARFIMA terbaik untuk meramalkan serta menganalisis perilaku nilai tukar rupiah terhadap *US Dollar* menggunakan data terbaru.

Permasalahan ketidakstabilan nilai tukar rupiah terhadap *US Dollar*, yang dalam beberapa tahun terakhir menunjukkan fluktuasi signifikan sulit diprediksi. Kondisi ini menimbulkan tantangan bagi pemerintah, pelaku pasar, dan berbagai sektor ekonomi dalam mengambil keputusan yang tepat. Oleh karena itu, diperlukan penelitian dengan metode peramalan yang mampu menangkap karakteristik data nilai tukar yang cenderung bersifat *long memory*. Dengan menggunakan pemodelan ARFIMA pada data nilai tukar rupiah terhadap *US Dollar* pada periode Januari 2023 – Maret 2025, penelitian ini secara eksplisit menganalisis permasalahan tersebut dengan menyertakan unsur *long memory*. Sehingga penelitian ini dilakukan dengan tujuan menentukan model ARFIMA terbaik untuk meramalkan serta menganalisis hasil peramalan data nilai tukar rupiah terhadap *US Dollar*. Penelitian ini diharapkan dapat memberikan kontribusi berupa hasil peramalan yang diharapkan menjadi referensi atau acuan bagi pengambil keputusan di masa depan.

2. TINJAUAN PUSTAKA

Nilai tukar mata uang atau yang dikenal sebagai kurs, merupakan harga suatu mata uang jika diukur terhadap mata uang di negara lain. Fluktuasi nilai tukar di pasar uang sangat dipengaruhi oleh kekuatan dan stabilitas nilai tukar pada masing-masing negara (Ardesfira, et al., 2022). Di Indonesia, mata uang yang berlaku secara resmi sebagai alat pembayaran adalah rupiah. Ketika rupiah melemah terhadap *US Dollar* (USD/IDR), barang-barang impor dari negara lain termasuk bahan baku untuk keperluan industri dan produk konsumsi menjadi

lebih mahal, sehingga bisa memicu inflasi di dalam negeri. Salah satu metode yang dapat memodelkan data keuangan, termasuk nilai tukar rupiah adalah model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA).

Model ARFIMA merupakan bagian dari metode analisis runtun waktu. Analisis runtun waktu bertujuan untuk mengamati serta meramalkan nilai di masa depan dengan mengoptimalkan metode yang digunakan. Dalam analisis runtun waktu, stasioneritas merupakan asumsi yang harus dipenuhi. Stasioneritas terbagi menjadi dua jenis, yaitu stasioneritas dalam rata-rata (mean) dan stacionesitas dalam varians. Pengujian stasioneritas terhadap rata-rata suatu data dapat dilakukan melalui evaluasi keberadaan akar unit. Salah satu metode yang umum digunakan untuk mendeteksi apakah suatu deret data waktu mengandung akar unit adalah uji *Augmented Dickey-Fuller* (ADF). Statistik uji ADF direpresentasikan pada persamaan (1).

$$t_{hitung} = \frac{\hat{\delta}}{SE(\hat{\delta})} \quad (1)$$

dengan $\hat{\delta}$ estimator *least square* dan $SE(\hat{\delta})$ *standart error* dari nilai estimasi δ . Hipotesis yang digunakan dalam pengujian ADF dapat dijelaskan sebagai berikut.

$H_0 : \delta = 0$ (Mengandung akar unit, sehingga data bersifat tidak stasioner)

$H_1 : \delta < 0$ (Tidak mengandung akar unit, sehingga data bersifat stasioner)

Dalam pemodelan data runtun waktu, sering kali ditemukan kondisi di mana nilai rata-rata (mean) tidak bersifat stasioner, jika data tidak stasioner dalam varians maka diperlukan perlakuan berupa transformasi data. Salah satu metode transformasi yang sering diterapkan pada penelitian adalah transformasi *Box-Cox*. Persamaan transformasi *Box-Cox* secara umum dinyatakan dalam persamaan (2).

$$T(Z_t) = \frac{Z_t^{\lambda-1}}{\lambda} \quad (2)$$

dengan λ parameter transformasi dan Z_t nilai aktual pada waktu ke- t . Transformasi *Box-Cox* hanya dapat diterapkan ketika $Z_t > 0$, karena nilai negatif tidak dapat ditransformasikan menggunakan bentuk pangkat. Pada kasus $\lambda = 0$, transformasi *Box-Cox* didefinisikan menggunakan bentuk logaritmik, yang dinyatakan dalam bentuk persamaan (3).

$$T(Z_t) = \ln(Z_t) \quad (3)$$

Salah satu kasus khusus dalam data runtun waktu adalah adanya karakteristik memori jangka panjang (*long memory*). Dalam konteks data deret waktu, *long memory* adalah proses yang menunjukkan ketergantungan memori jangka panjang dengan pengaruh dari observasi masa lalu bertahan lebih lama dibandingkan dengan data jangka pendek (*short memory*). Data yang bersifat *long memory* biasanya ditunjukkan oleh pola autokorelasi pada ACF yang menurun secara lambat dan tidak eksponensial.

Selain menggunakan plot ACF, terdapat nilai statistik yang dikhawasukan untuk menguji apakah data bersifat *long memory*. Nilai Hurst (H) yang diperoleh dengan menggunakan metode *Rescaled Range Statistics* (R/S) bisa mengidentifikasi adanya sifat *long memory* pada data runtun waktu. Nilai Hurst dapat diperoleh dengan menggunakan metode *Ordinary Least Square* (OLS) yang direpresentasikan pada persamaan (4).

$$H = \frac{\sum_{j=1}^T (X_j - \bar{X})(Y_j - \bar{Y})}{\sum_{j=1}^T (X_j - \bar{X})^2} \quad (4)$$

dengan n jumlah total pengamatan, X_j nilai pengamatan dari variabel X pada waktu ke- j , Y_j nilai pengamatan dari variabel Y pada waktu ke- j , \bar{X} rata-rata dari semua pengamatan variabel X dan \bar{Y} rata-rata dari semua pengamatan variabel Y , dengan $X_j = \log t$ dan $Y_j = \log(R/S)_t$.

Identifikasi sifat pada data berdasarkan nilai H dapat dinyatakan sebagai berikut.

- a. Jika nilai $H = 0.5$, maka menunjukkan karakteristik acak.

- b. Jika nilai H pada data berada pada rentang $0 < H < 0.5$, maka menunjukkan karakteristik *short memory*.
- c. Jika nilai H pada data berada pada rentang $0.5 < H < 1$, maka menunjukkan karakteristik *long memory*.

Model ARFIMA merupakan perluasan dari model *Autoregressive Integrated Moving Average* (ARIMA). Pada model ARIMA(p,d,q), parameter d merupakan derajat pembedaan (*differencing*) yang bernilai bilangan bulat dan digunakan untuk menghilangkan unsur *non-stasioner* pada data deret waktu. Namun demikian, ketika data menunjukkan pola *long memory*, penggunaan nilai d bilangan bulat pada ARIMA tidak lagi memadai. Keterbatasan tersebut dapat diatasi dengan model ARFIMA ditambahkan komponen pembedaan fraksional pada parameter integrasi, sehingga nilai d diperbolehkan bernilai bilangan pecahan ($0 < d < 0.5$). Sehingga model ARFIMA memberikan fleksibilitas lebih besar dalam menangani data yang terbukti bersifat *long memory*. Model ARFIMA(p,d,q) secara umum direpresentasikan pada persamaan (5).

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)a_t \quad (5)$$

dengan Z_t nilai aktual pada waktu ke- t , d parameter pembeda ($0 < d < 0.5$), $(1 - B)^d$ operator pembeda ($0 < d < 0.5$), B operator backward shift, a_t white noise atau *error term* pada waktu ke- t , $\phi_p(B) = 1 - \phi_1B - \dots - \phi_pB^p$ polinomial *autoregressive* ke- p dan $\theta_q(B) = 1 - \theta_1B - \dots - \theta_qB^q$ polinomial *moving average* ke- q .

Penetapan nilai pembeda (d) dalam model ARFIMA bisa dilakukan dengan metode estimasi parameter pembeda yang salah satunya adalah metode *Rescaled Range Statistics* (R/S). Nilai *Hurst* berperan dalam mengestimasi parameter pembeda dalam model ARFIMA, proses pengestimasian nilai pembeda dengan memanfaatkan metode R/S diperoleh dengan menggunakan persamaan (6).

$$\hat{d} = H - 0.5 \quad (6)$$

Pemodelan ARFIMA pada penelitian ini menggunakan metode *Box-Jenkins* yang melalui tahapan identifikasi model, estimasi parameter, uji diagnostik, serta seleksi model terbaik. Proses identifikasi model ARFIMA(p,d,q) untuk penetapan p dan q bisa diperoleh dengan cara mengamati pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) pada data yang telah melalui proses *differencing*. *Maximum Likelihood Estimation* (MLE) merupakan salah satu metode yang umum digunakan untuk mengestimasi parameter dalam model AR(p) dan MA(q). Metode ini dipilih karena mampu memanfaatkan seluruh informasi yang terkandung dalam data untuk menghasilkan estimasi parameter yang optimal. Proses MLE disederhanakan dengan meninjau model AR(1) dan MA(1). Pada model AR(1) dengan $Z_t = \phi_p Z_{t-1} + a_t$, penurunan *log-likelihood* menghasilkan minimisasi $\sum(Z_t - \phi_p Z_{t-1})^2$. Dengan menyetarakan turunan pertamanya terhadap ϕ_p , diperoleh estimasi seperti pada persamaan (7).

$$\hat{\phi}_p = \frac{\sum_{t=p+1}^n Z_{t-1}Z_t}{\sum_{t=p+1}^n Z_{t-1}^2} \quad (7)$$

Demikian pula pada model MA(1) dengan $Z_t = a_t - \theta_q a_{t-1}$, penurunan *log-likelihood* menghasilkan minimisasi $\sum(Z_t - \theta_q a_{t-1})^2$. Dengan menyetarakan turunan pertama fungsi tersebut terhadap θ_q , maka diperoleh bentuk estimasi seperti persamaan (8).

$$\hat{\theta}_q = \frac{\sum_{t=q+1}^n Z_t a_{t-1}}{\sum_{t=q+1}^n a_{t-1}^2} \quad (8)$$

Dalam menentukan tingkat signifikansi parameter dalam model ARFIMA(p,d,q) diperlukan standar pengujian statistik terhadap parameter estimasi. Secara umum, statistik uji yang digunakan adalah uji *Z-Statistic* yang ditunjukkan pada persamaan (9) dengan hipotesis sebagai berikut.

H_0 : Tidak ada perbedaan atau efek yang signifikan antara dua variabel yang diuji

H_1 : Ada perbedaan atau efek yang signifikan antara dua variabel yang diuji

$$Z = \frac{\hat{\beta}}{SE(\hat{\beta})} \quad (9)$$

Nilai $Z = 1.96$ sering digunakan dalam pengujian hipotesis dua sisi dengan tingkat signifikansi $\alpha = 0.05$ (5%).

Uji diagnostik dilakukan untuk memeriksa apakah data sudah bersifat *white noise*, yaitu memenuhi uji autokorelasi dan normalitas. Pengujian autokorelasi residual data dilakukan dengan menggunakan pengujian *L-Jung Box*, yang direpresentasikan dengan statistik uji pada persamaan (10) dengan hipotesis sebagai berikut.

H_0 : Residual pada data tidak menunjukkan adanya autokorelasi (bersifat *white noise*)

H_1 : Residual pada data menunjukkan adanya autokorelasi (tidak bersifat *white noise*)

$$Q = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)} \quad (10)$$

dengan $\hat{\rho}_k$ estimasi ACF residual *lag ke-k*, n banyak data dan K banyak maksimum *lag*.

Pengujian *Kolmogorov-Smirnov* digunakan untuk memeriksa apakah residual mengikuti distribusi normal. Pengujian normalitas yang dilakukan direpresentasikan dengan statistik uji pada persamaan (11) dengan hipotesis sebagai berikut.

H_0 : Residual berdistribusi normal

H_1 : Residual tidak berdistribusi normal

$$D = \text{Sup}_x |S(x) - F_0(x)| \quad (11)$$

dengan $S(x)$ adalah nilai berdistribusi kumulatif sampel dan $F_0(x)$ nilai berdistribusi kumulatif yang berasal dari distribusi normal.

Seleksi model ARFIMA yang digunakan dalam peramalan didasarkan pada nilai *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC) terkecil. Formulasi nilai AIC dan BIC dinyatakan pada persamaan (12) dan (13).

$$AIC = -2 \ln(L) + 2k \quad (12)$$

$$BIC = -2 \ln(L) + k \ln(n) \quad (13)$$

dengan L nilai *likelihood* maksimum, k adalah jumlah parameter dalam model dan n jumlah observasi.

Penelitian ini menggunakan metrik evaluasi *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Squared Error* (RMSE) dalam mengevaluasi kinerja model peramalan (*forecasting*). Formula untuk masing-masing nilai MAE, MAPE dan RMSE dinyatakan pada persamaan (14), (15) dan (16).

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (14)$$

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (16)$$

dengan n adalah jumlah observasi, y_t nilai aktual pada waktu ke- t dan \hat{y}_t nilai hasil peramalan pada waktu ke- t .

3. METODE PENELITIAN

Data yang digunakan pada penelitian adalah data sekunder yang merupakan data harian nilai tukar rupiah terhadap *US Dollar* (USD/IDR), diperoleh melalui website resmi Bank Indonesia untuk periode bulan Januari 2023 sampai dengan bulan Maret 2025 dengan total observasi sebanyak 535. Penelitian ini dilakukan dengan menggunakan *software*/perangkat lunak *R versi 4.3.0* dan akan dilaksanakan melalui beberapa tahapan sebagai berikut.

1. Mengumpulkan data nilai tukar rupiah terhadap *US Dollar* (USD/IDR) untuk periode Januari 2023 hingga bulan Maret 2025 melalui situs resmi Bank Indonesia.
2. Melakukan eksplorasi data dengan meninjau plot deret waktu dari data awal serta melakukan analisis statistik deskriptif terhadap data tersebut, meliputi nilai minimum, maksimum, rata-rata, median dan pola data yang terlihat dari grafik.
3. Melakukan *splitting data* dengan membagi data bulan Januari 2023 hingga Februari 2025 sebagai data *training* dan data Maret 2025 sebagai data *testing*.
4. Melakukan pemeriksaan terhadap kestasioneran data *training* dengan beberapa tahapan sebagai berikut.
 - a) Memeriksa kestasioneritasan dalam rata-rata dengan menggunakan uji *Augmented Dickey-Fuller* (ADF) yang ditunjukkan pada persamaan (1).
 - b) Memeriksa kestasioneran data dalam varians, jika data tidak stasioner dalam varians, maka dilakukan transformasi data dengan menggunakan fungsi *Box-Cox transformation* yang ditunjukkan pada persamaan (2).
5. Mengidentifikasi adanya sifat *long memory* pada data *training* dengan melihat pola ACF dan menggunakan nilai Hurst (H) yang dapat dihasilkan dari persamaan (4).
6. Menetapkan nilai estimasi nilai d melalui metode *Rescaled Range Statistics* (R/S) yang dapat diperoleh dengan menghitung persamaan (6).
7. Melakukan proses *differencing* menggunakan nilai estimasi d yang telah diperoleh.
8. Membentuk beberapa model ARFIMA pada data *training* dengan beberapa langkah sebagai berikut.
 - a) Identifikasi orde model ARFIMA dengan memperhatikan pola ACF untuk MA(p) dan PACF untuk AR(q) pada data yang telah dilakukan *differencing*.
 - b) Estimasi parameter ϕ dan θ pada model tentatif yang telah dibentuk dengan menggunakan metode *Exact Maximum Likelihood* dengan persamaan (7) dan (8).
 - c) Uji diagnostik model yang meliputi pengujian autokorelasi menggunakan *L-Jung Box* dengan persamaan (10) dan uji normalitas dengan menggunakan uji *Kolmogorov Smirnov* dengan persamaan (11).
 - d) Seleksi model ARFIMA terbaik yang digunakan untuk peramalan didasarkan pada nilai AIC dan BIC terkecil dengan mengacu pada persamaan (12) dan (13).
9. Peramalan menggunakan data *testing* dengan menggunakan model ARFIMA terbaik yang telah diperoleh.
10. Menghitung nilai MAE, RMSE dan MAPE pada data aktual dan data hasil peramalan dengan mengacu pada persamaan persamaan (14), (15) dan (16).

4. HASIL DAN PEMBAHASAN

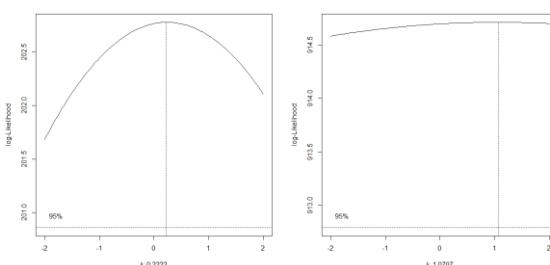
Tahap awal sebelum melakukan peramalan adalah mengamati pola data. Pola tersebut dapat dilihat melalui plot time series untuk mengidentifikasi bentuk dan karakteristik data yang terbentuk.



Gambar 2 Plot Deret Waktu Nilai Tukar Rupiah terhadap US Dollar (USD/IDR) Periode Januari 2023 – Februari 2025

Gambar 2 mengindikasikan adanya tren naik pada data nilai tukar rupiah terhadap US Dollar (USD/IDR), sehingga dapat dikatakan bahwa data tidak stasioner dalam rata-rata. Selain itu, tidak diitunjukkan adanya pola musiman pada data tersebut jika dilihat secara visual. Meskipun pada Gambar 1 sebelumnya ditampilkan grafik nilai tukar Rupiah terhadap *US Dollar* untuk periode Oktober 2024 hingga Maret 2025 sebagai ilustrasi awal, analisis deret waktu pada penelitian ini menggunakan data harian dari bulan Januari 2023 hingga Maret 2025. Penggunaan data dengan periode yang lebih panjang pada tahap analisis bertujuan untuk menangkap pola pergerakan nilai tukar secara lebih komprehensif, khususnya tren jangka panjang, serta indikasi adanya sifat *long memory*.

Setelah mengamati pola data, langkah berikutnya adalah melakukan pemeriksaan stasioneritas data dalam varians. Jika nilai $\lambda = 1$ maka data tersebut sudah memenuhi kriteria stasioner dalam varians.



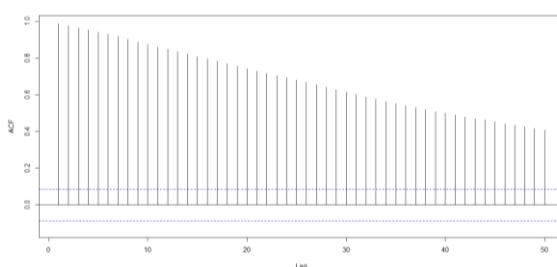
Gambar 3. Plot Box-Cox Sebelum (kiri) dan Sesudah Transformasi (kanan)

Hasil pemeriksaan yang ditunjukkan pada Gambar 3 (kiri) diperoleh $\lambda = 0.2222$ yang berarti bahwa data belum stasioner dalam varians, sehingga diperlukan penanganan berupa transformasi.

$$T(Z_t) = \frac{Z_t^{0.2222} - 1}{0.2222} \quad (17)$$

Berdasarkan hasil pemeriksaan yang ditunjukkan pada Gambar 3 (kanan), data yang telah ditransformasi dapat dikatakan telah stasioner dalam varians karena menghasilkan nilai $\lambda = 1.0707$, dimana nilai tersebut mendekati 1. Setelah data dinyatakan stasioner terhadap varians, langkah berikutnya adalah melakukan pengecekan stasioneritas data dalam rata-rata menggunakan uji *Augmented Dickey Fuller* (ADF).

Hasil uji ADF Data Sesudah Transformasi menunjukkan bahwa nilai *p-value* sebesar $0.1740 > 0.05$ ($\alpha = 5\%$), sehingga berdasarkan kriteria uji ADF diambil keputusan gagal tolak H_0 . Dengan demikian dapat dinyatakan bahwa data transformasi tidak stasioner dalam rata-rata dan memerlukan penanganan berupa *differencing*. Hanya saja pada data *long memory differencing* akan dilakukan dengan d bernilai bilangan pecahan atau desimal. Pengujian *long memory* terdiri dari dua cara, yaitu dengan mengamati plot *Autocorrelation Function* (ACF) yang kemudian didukung dengan menggunakan nilai *Hurst* (H). Apabila plot ACF dari data tidak menunjukkan penurunan secara eksponensial, namun menurun secara perlahan maka secara visual data dikategorikan memiliki sifat *long memory*.



Gambar 4. Plot ACF Data Sesudah Transformasi

Gambar 4 menunjukkan bahwa pergerakan autokorelasi ACF tidak menurun secara eksponensial, melainkan menurun secara perlahan sehingga mengindikasikan bahwa data nilai tukar rupiah terhadap *US dollar* (USD/IDR) bersifat *long memory* atau memiliki ketergantungan memori jangka panjang. Selanjutnya proses identifikasi sifat *long memory*, data dapat dinyatakan bersifat *long memory* jika nilai H berada pada rentang $0.5 < H < 1$.

Tabel 1. Nilai *Hurst*

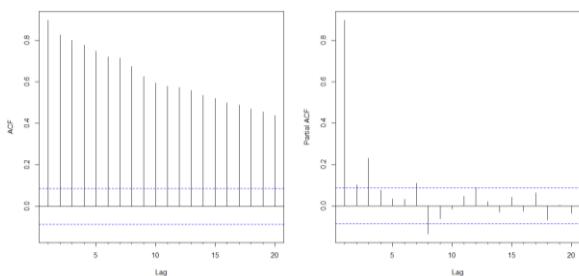
	Nilai
<i>Simple R/S Hurst Estimation</i>	0.837162
<i>Corrected R over S Hurst Exponent</i>	0.982677
<i>Empirical Hurst Exponent</i>	0.959417
<i>Corrected Empirical Hurst Exponent</i>	0.933359
<i>Theoretical Hurst Exponent</i>	0.546488

Berdasarkan Tabel 1, diperoleh beberapa hasil perhitungan nilai H dengan menggunakan beberapa metode. Penelitian ini memanfaatkan salah satu nilai *Hurst* (H) yang dihitung melalui metode *Rescaled Range Statistics* (R/S), yaitu *Simple R/S Hurst Estimation* yang bernilai sebesar 0.837162. Meskipun seluruh metode menunjukkan bahwa nilai H berada pada interval $0.5 < H < 1$, yang mengindikasikan adanya sifat *long memory* pada data, metode *Simple R/S Hurst Estimation* dipilih karena metode ini merupakan bentuk dasar dari perhitungan Hurst dan paling banyak digunakan dalam penelitian awal analisis *long memory*. Selain itu, metode ini lebih stabil digunakan pada data deret waktu berukuran sedang, seperti data nilai tukar dalam penelitian ini. Metode *Simple R/S Hurst Estimation* juga tidak memerlukan koreksi tambahan yang dapat menambah kompleksitas perhitungan. Dengan mempertimbangkan konsistensi hasil serta kebutuhan penelitian yang menitikberatkan pada estimasi parameter pembedaan fraksional, metode *Simple R/S Hurst Estimation* menjadi pilihan yang tepat untuk mengestimasi nilai d .

$$\hat{d} = 0.837162 - 0.5 = 0.337162 \quad (18)$$

Nilai estimasi d ditentukan dengan mengurangkan nilai H terpilih dengan 0.5, sehingga diperoleh nilai estimasi d sebesar 0.337162. Dari hasil estimasi nilai d yang ditemukan, diketahui bahwa data nilai tukar rupiah terhadap *US Dollar* memiliki estimasi nilai d yang terletak pada rentang $0 < d < 0.5$. Sehingga setelah memperoleh nilai estimasi d , maka selanjutnya adalah proses *differencing* dengan melibatkan data yang sudah ditransformasi dan nilai estimasi d . Setelah data dilakukan proses *differencing*, langkah selanjutnya adalah memeriksa kembali apakah data tersebut telah memenuhi syarat stasioneritas dalam rata-rata. Pemeriksaan ini kembali dilakukan menggunakan uji *Augmented Dickey-Fuller* (ADF), dimana uji tersebut dilakukan untuk mendeteksi data yang sudah melalui *differencing* sudah memenuhi kriteria stasioner dalam rata-rata atau masih diperlukan langkah tambahan untuk mengubahnya menjadi stasioner. Hasil uji ADF data sesudah *differencing* menunjukkan bahwa nilai *p-value* sebesar $0.024 < 0.05$ ($\alpha = 5\%$), sehingga berdasarkan kriteria uji ADF diambil keputusan tolak H_0 . Dengan demikian dapat dinyatakan bahwa data sesudah *differencing* telah stasioner dalam rata-rata dan dapat dilanjutkan ke tahap analisis selanjutnya.

Tahapan analisis selanjutnya adalah identifikasi model tentatif ARFIMA(p,d,q) dengan mengamati pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Plot ACF dan PACF yang digunakan adalah plot data setelah *differencing* dengan nilai estimasi d sebesar 0.337162 yang diperoleh menggunakan metode R/S.



Gambar 5. Plot ACF (kiri) dan PACF (kanan) Setelah Differencing

Gambar 5 menunjukkan *lag* pada plot ACF yang tampak turun secara lambat, dengan demikian model tentatif yang terbentuk akan memiliki orde *moving average* MA(*q*) tak hingga. Namun pada penelitian ini, peneliti membatasi bahwa orde MA (*q*) yang dibentuk adalah MA(0), MA(1), MA(2) dan MA(3). Kemudian berdasarkan plot PACF yang menunjukkan *cut-off* pada lag ke-3, dipertimbangkan beberapa kemungkinan orde AR(*p*) yang sesuai, yaitu AR(0), AR(1), AR(2), AR(3), dan AR(4). Dengan demikian, secara keseluruhan terdapat 19 model tentatif sebagaimana ditampilkan pada Tabel 2 untuk dianalisis lebih lanjut. Pembatasan ini dilakukan untuk menjaga efisiensi model, menghindari kompleksitas berlebihan, serta memastikan bahwa model tetap dapat diestimasi dengan baik mengingat ukuran data yang digunakan.

Tabel 2. Model Tentatif ARFIMA

No	Model Tentatif	No	Model Tentatif	No	Model Tentatif
1	ARFIMA(0,d,1)	8	ARFIMA(2,d,0)	15	ARFIMA(3,d,3)
2	ARFIMA(0,d,2)	9	ARFIMA(2,d,1)	16	ARFIMA(4,d,0)
3	ARFIMA(0,d,3)	10	ARFIMA(2,d,2)	17	ARFIMA(4,d,1)
4	ARFIMA(1,d,0)	11	ARFIMA(2,d,3)	18	ARFIMA(4,d,2)
5	ARFIMA(1,d,1)	12	ARFIMA(3,d,0)	19	ARFIMA(4,d,3)
6	ARFIMA(1,d,2)	13	ARFIMA(3,d,1)		
7	ARFIMA(1,d,3)	14	ARFIMA(3,d,2)		

Selanjutnya adalah proses estimasi parameter ϕ dan θ pada model tentatif ARFIMA(*p,d,q*) yang telah dibentuk. Estimasi nilai parameter model ARFIMA untuk data nilai tukar rupiah terhadap *US dollar* (USD/IDR) berdasarkan model tentatif dengan menggunakan nilai estimasi parameter *d* = 0.337162 ditunjukkan pada tabel 3.

Tabel 3. Uji Signifikansi Parameter Model Tentatif

No	ARFIMA(<i>p,d,q</i>)	Parameter	SE	Z	Keterangan
1	ARFIMA(0,d,1)	$\hat{\theta}_1 = -7.2783$	0.0243	-29.9238	Signifikan
2	ARFIMA(0,d,2)	$\hat{\theta}_1 = -0.7417$	0.0401	-18.4900	Signifikan
		$\hat{\theta}_2 = -0.3392$	0.0383	-8.8522	Signifikan
3	ARFIMA(1,d,0)	$\hat{\phi}_1 = 0.9875$	0.0081	120.6829	Signifikan
4	ARFIMA(1,d,1)	$\hat{\phi}_1 = 0.9939$	0.0054	183.7749	Signifikan
		$\hat{\theta}_1 = -0.1940$	0.0727	-2.6683	Signifikan
		$\hat{\phi}_1 = 0.1929$	0.0708	2.7224	Signifikan
5	ARFIMA(2,d,1)	$\hat{\phi}_2 = 0.7903$	0.0684	11.5489	Signifikan
		$\hat{\theta}_1 = -0.9064$	0.0462	-19.5864	Signifikan
		$\hat{\phi}_1 = 0.9467$	0.0855	11.0619	Signifikan
6	ARFIMA(3,d,0)	$\hat{\phi}_2 = -0.1654$	0.0689	-2.3986	Signifikan
		$\hat{\phi}_3 = 0.1966$	0.0513	3.8331	Signifikan

Kriteria pengambilan keputusan tolak H_0 jika menunjukkan nilai Z hitung ($|Z|$) berada pada $-1.96 > |Z| > 1.96$. Berdasarkan Tabel 3, sebanyak 4 model terpilih yang memenuhi kriteria signifikansi parameter. Model terpilih ini nantinya yang akan dilanjutkan pada tahapan analisis berikutnya, yaitu uji diagnostik model. Pengujian diagnostik yang harus dilakukan meliputi uji autokorelasi dan normalitas.

Tabel 4. Uji Diagnostik Model Terpilih

No	Model ARFIMA	<i>P-value</i>		Keterangan
		<i>L-Jung Box</i>	<i>KS</i>	
1	ARFIMA(1,d,0)	0.2773	0.0731	Acak dan Normal
2	ARFIMA(1,d,1)	0.7106	0.0571	Acak dan Normal
3	ARFIMA(2,d,1)	0.9178	0.0749	Acak dan Normal
4	ARFIMA(3,d,0)	0.9998	0.0524	Acak dan Normal

Berdasarkan Tabel 4, hasil pengujian asumsi residual menunjukkan bahwa model ARFIMA(1,d,0), ARFIMA(1,d,1), ARFIMA(2,d,1) dan ARFIMA(3,d,0) dengan nilai estimasi $d = 0.337162$ merupakan model yang memenuhi uji diagnostik model, baik untuk autokorelasi maupun normalitas. Langkah selanjutnya adalah memilih model yang paling sesuai untuk model ARFIMA(p,d,q) yang ditentukan dengan membandingkan nilai *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC) terkecil. Nilai AIC dan BIC untuk setiap model tentatif yang terbentuk dengan nilai estimasi $d = 0.337162$ pada data nilai tukar rupiah terhadap *US Dollar* (USD/IDR) ditunjukkan pada Tabel 5.

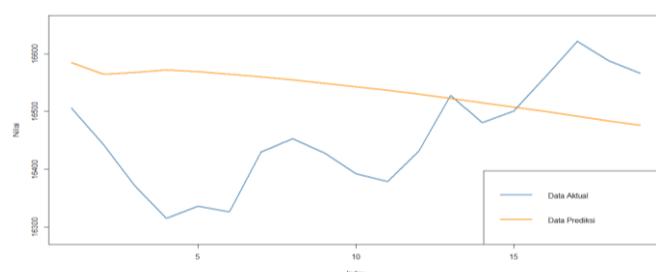
Tabel 5. Model ARFIMA Terbaik

No	Model ARFIMA	AIC	BIC
1	ARFIMA(1,d,0)	4221.96	4238.95
2	ARFIMA(1,d,1)	4218.53	4239.76
3	ARFIMA(2,d,1)	4210.86	4236.34
4	ARFIMA(3,d,0)	4210.28	4235.76

Tabel 5 menunjukkan bahwa model ARFIMA(3,d,0) dengan nilai estimasi $d = 0.337162$ memiliki nilai AIC dan BIC terkecil, sehingga model tersebut dinyatakan sebagai model terbaik yang baik untuk peramalan. Dengan demikian model persamaan dari model ARFIMA terbaik dapat dituliskan dalam persamaan sebagai berikut:

$$(1 - 0.9467B + 0.1654B^2 - 0.1966B^3)(1 - B)^{0.337162}Z_t = a_t \quad (19)$$

Berdasarkan model terbaik tersebut, langkah selanjutnya yang dilakukan adalah melakukan proses peramalan (*forecasting*) untuk data harian pada periode bulan Maret 2025, karena website Bank Indonesia hanya menyediakan *update* data pada hari kerja sehingga hanya terdapat total sebanyak 19 data harian selama bulan Maret 2025. Adapun hasil dari peramalan untuk periode Maret 2025 disajikan pada Gambar 6.



Gambar 6. Pergerakan Data Asli dan Hasil Peramalan

Hasil peramalan menunjukkan adanya kecenderungan penurunan (penguatan) nilai Rupiah terhadap *US Dollar* (data harian). Namun, ketika dibandingkan dengan data aktual pada periode yang sama, terlihat bahwa nilai Rupiah justru mengalami kenaikan (pelemahan). Perbedaan ini terjadi akibat adanya faktor eksternal yang tidak dapat diprediksi oleh model, yaitu kebijakan tarif yang dikeluarkan oleh Presiden Amerika Serikat Donald Trump yang memicu tekanan eksternal terhadap nilai tukar Rupiah. Dengan demikian, divergensi antara hasil prediksi dan data aktual mencerminkan adanya kejadian tak terduga yang memengaruhi kondisi ekonomi secara tiba-tiba dan berada di luar pola historis yang ditangkap oleh model.

Evaluasi kinerja model peramalan dilakukan menggunakan tiga metrik utama, yaitu MAE, RMSE, dan MAPE. Nilai MAE sebesar 122 rupiah menunjukkan bahwa rata-rata selisih absolut antara nilai aktual dan nilai hasil peramalan hanya sekitar 122 rupiah dari nilai tukar aktual yang berada di kisaran Rp 16.000 per USD. Nilai RMSE sebesar 140.9505 rupiah menunjukkan adanya beberapa kesalahan prediksi yang sedikit lebih besar, namun tetap berada dalam rentang yang sangat kecil dibandingkan level nilai tukar tersebut. Sementara itu, nilai MAPE sebesar 0.7431% mengindikasikan bahwa kesalahan relatif model kurang dari 1%, menandakan tingkat akurasi prediksi yang sangat baik. Secara keseluruhan, ketiga metrik ini memperlihatkan bahwa model ARFIMA menghasilkan peramalan yang cukup akurat dan responsif terhadap dinamika pergerakan nilai tukar, dengan kesalahan prediksi yang relatif kecil dibandingkan skala nilai aktual jika tidak terdapat faktor eksternal yang akan berpengaruh signifikan terhadap ketidaksesuaian hasil peramalan.

5. KESIMPULAN

Data nilai tukar rupiah terhadap *US Dollar* (USD/IDR) terbukti bersifat *long memory* berdasarkan nilai Hurst yang sebesar 0.837162, sehingga model ARFIMA sesuai untuk mengatasi kondisi karakteristik data penelitian. Model ARFIMA terbaik yang terbentuk adalah ARFIMA(3,0.337162,0) dengan nilai AIC 4210.28 dan BIC 4235.76. Berdasarkan hasil penelitian, model ARFIMA mampu memberikan peramalan nilai tukar Rupiah terhadap *US Dollar* dengan tingkat akurasi yang sangat baik ketika kondisi pasar bergerak sesuai pola historis yang stabil. Hal ini terlihat dari nilai MAE, RMSE, dan MAPE yang relatif kecil dibandingkan level nilai tukar aktual. Meskipun demikian, perbandingan antara hasil peramalan dan data aktual menunjukkan terjadinya divergensi akibat munculnya faktor eksternal yang tidak dapat diantisipasi oleh model, yaitu kebijakan tarif Presiden Amerika Serikat Donald Trump yang menimbulkan tekanan eksternal terhadap Rupiah. Kejadian tidak terduga ini menegaskan bahwa model berbasis pola historis memiliki keterbatasan dalam merespons perubahan eksternal yang sifatnya tiba-tiba. Secara keseluruhan, penelitian ini menyimpulkan bahwa model ARFIMA efektif dalam melakukan peramalan jangka pendek pada kondisi pasar yang relatif stabil, namun tetap memerlukan pelengkap berupa variabel eksternal atau pendekatan model struktural untuk meningkatkan ketangguhan prediksi pada situasi yang dipengaruhi gejolak ekonomi global.

DAFTAR PUSTAKA

- Ardesfira, G., Zedha, H., Rahmadhiyanti, J., Fazana, I., Rahima, S., & Anwar, S. (2022). Peramalan Nilai Tukar Rupiah Terhadap Dolar Amerika Dengan Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA). *Journal of Probability and Statistics*.

- Asif, R., & Frömmel, M. (2022). Testing Long memory in the exchange rates and its Implications for the adaptive market hypothesis. *Physica A Statistical Mechanics and its Applications*, 593(5).
- Azan, A., Matoto, N., & Mah, P. (2021). The Comparison between ARIMA and ARFIMA Model to Forecast. *Journal of Computing Research and Innovation Kijang Emas (Gold) Prices in Malaysia using MAE, RMSE and MAPE*, 22-33.
- Biga, A. W., Hasan, I., & Nurwan. (2025). Perbandingan Metode ARFIMA dan Metode ARIMA-FFNN (Studi Kasus: Harga Saham di PT. Telekomunikasi Indonesia Tbk). *Jurnal Ilmiah Multidisiplin*, 4(2), 760-768.
- Faustina, T. (2023). Nilai Tukar Rupiah Menguat: Bagaimana Dampaknya pada Ekonomi Lokal. *Jurnal Pendidikan dan Sosial Humaniora*, 127-135.
- Hasan, I., Janur, M., & Nurwan. (2023). Penerapan Model Arfima-Garch Menggunakan Variasi Estimasi Parameter Pembeda D Pada Data Long Memory. *Jurnal Statistika*, 474-485.
- Imani, N. D., Tarno, & Saputra, B. (2023). Prediksi Harga Daging Sapi di Kabupaten Brebes Menggunakan Pemodelan ARFIMA dengan Efek GARCH. *Jurnal Gaussian*, 12, 570-580.
- Kartikasari, P., Yasin, H., & Maruddani, D. (2021). Autoregressive Fractionally Integrated Moving Average (ARFIMA) Model to Predict COVID-19 Pandemic Cases in Indonesia. *Media Statistika*, 14(1), 44-55.
- Lahmiri, S., & Bekiros, S. (2021). The Effect of COVID-19 on Long Memory in Returns and Cryptocurrency and Stock Markets. *Chaos, Solitons and Fractals*, 151, 1-8.
- Melani, V. D., Miftahuddin, & Subianto, M. (2022). Seleksi Model ARFIMA-GPH dan Intervensi Multi Input pada Indeks Harga Perdagangan Besar Indonesia. *Jurnal Gaussian*, 11, 163-172.
- Rismawati, N., & Sugiman. (2022). Long Memory Volatility Model dengan ARFIMA-HYGARCH untuk Meramalkan Return Indeks Harga Saham Gabungan (IHSG). *UNNES Journal of Mathematics*.
- Sinaga, M. R., Sutarman, & Rakhmawati, F. (2024). Pemodelan Autoregressive Fractionally Integrated Moving Average (ARFIMA) untuk Aktivitas Curah Hujan di Kota Medan. *Jurnal Ilmiah Pendidikan Matematika, Matematika dan Statistika*, 5(1), 198-206.
- Titus, C. M., Wanjoya, A., & Mageto, T. (2021). Time Series Modeling of Guinea Fowls Production in Kenya Using the ARIMA and ARFIMA Models. *International Journal of Data Science and Analysis*, 7(1), 1-7.
- Winanti, G. L., Ispriyanti, D., & Sugito. (2023). Pemodelan Indeks Harga Perdagangan Besar (IHPB) Sektor Ekspor Menggunakan ARFIMA-GARCH. *Jurnal Gaussian*, 12, 52-60.
- Zedha, H. F., Siregar, S., Rahmi, R., Jannah, S., Sandi, R., Irawan, A., & Anwar, S. (2025). Penerapan Metode Triple Exponential Smoothing dan ARFIMA pada Peramalan Nilai Tukar Rupiah terhadap Dollar Amerika. *Jurnal Sains Matematika dan Statistika*, 11(1), 1-15.