

# Statistika FMIPA ULM

## ARTIKEL ILMIAH GAUSSIAN - AYU FAJAR RUSADI.docx

-  Paper 4
  -  Statistika
  -  Lambung Mangkurat University
- 

### Document Details

**Submission ID**

trn:oid:::1:3255093710

12 Pages

**Submission Date**

May 20, 2025, 10:32 AM GMT+7

4,329 Words

**Download Date**

May 20, 2025, 10:35 AM GMT+7

27,425 Characters

**File Name**

ARTIKEL\_ILMIAH\_GAUSSIAN\_-\_AYU\_FAJAR\_RUSADI.docx

**File Size**

5.5 MB

# 16% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

## Filtered from the Report

- ▶ Bibliography
  - ▶ Quoted Text
- 

## Top Sources

16%	 Internet sources
13%	 Publications
7%	 Submitted works (Student Papers)

---

## Top Sources

- 16% Internet sources  
13% Publications  
7% Submitted works (Student Papers)
- 

## Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

Rank	Type	Source	Percentage
1	Internet	lib.unnes.ac.id	3%
2	Student papers	Universitas Diponegoro	3%
3	Internet	repository.ub.ac.id	2%
4	Internet	link.springer.com	1%
5	Internet	ojs.unm.ac.id	<1%
6	Internet	repository.ung.ac.id	<1%
7	Internet	jurnal.untan.ac.id	<1%
8	Student papers	University of Durham	<1%
9	Publication	Marcel Laverda Subiyanto, Sediono Sediono, Elly Ana, M. Fariz Fadillah Mardianto,...	<1%
10	Internet	journal.uinjkt.ac.id	<1%
11	Internet	journal.unnes.ac.id	<1%

12 Internet

www.neliti.com <1%

13 Student papers

ESC Rennes <1%

14 Internet

repository.unair.ac.id <1%

15 Student papers

Universitas Pelita Harapan <1%



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

**Ayu Fajar Rusadi<sup>1</sup>, Yeni Rahkmawati<sup>2\*</sup>, Fitri Handayani<sup>3</sup>**

<sup>1,2</sup> Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lambung Mangkurat

<sup>3</sup> Badan Pusat Statistik Provinsi Kalimantan Selatan

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

**DOI: 10.14710/J.GAUSS.XX.X.XX-XX**

**Article Info:**

Received:

Accepted:

Available Online:

**Keywords:**

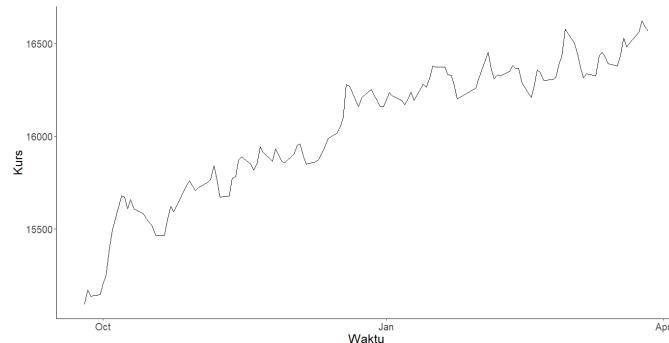
ARFIMA; Exchange Rate of Rupiah; US Dollar; Time Series Analysis; Long Memory

**Abstract:** The Autoregressive Fractionally Integrated Moving Average (ARFIMA) model is employed to analyze data exhibiting long memory characteristics using 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, totalling 535 observations. The results indicate a general weakening trend of the Rupiah during this period. The Hurst exponent ( $H = 0.8372489$ ), which falls within the range  $0.5 < H < 1$ , confirms the presence of long memory properties. The best fitting ARFIMA model is identified as ARFIMA(2,0.3372489,1), with a BIC value of 4387.69. The model equation is:  $(1 - 0.191338B - 0.792988B^2)(1 - B)^{0.3372489}Z_t = (1 + 0.908902B)a_t$ .

Forecasting results show a downward trend, suggesting potential appreciation of the rupiah against the USD in the future. These findings provide valuable insights into exchange rate dynamics and have important implications for economic planning and policy in Indonesia.

### **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 berfluktiasi seiring berjalananya waktu.



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

3 Berdasarkan Gambar 1, pergerakan pola data nilai tukar rupiah terhadap *US Dollar* (*USD/IDR*) menunjukkan kenaikan (pelemahan) atau memiliki pola tren naik, hal ini mengidentifikasi bahwa nilai rupiah secara konsisten terus melemah. Pelemahan nilai tukar rupiah terhadap *US Dollar* dapat menghambat aktivitas impor yang berpotensi mengganggu pemenuhan kebutuhan barang dalam negeri. Jika hal ini terjadi, maka perekonomian tentu terdampak secara negatif. 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, sehingga diperlukan penelitian berupa peramalan nilai tukar rupiah untuk beberapa periode di masa depan sebagai referensi dalam mengamati berbagai bentuk perubahan yang akan terjadi.

5 14 Nilai tukar menunjukkan karakteristik *long memory*, yaitu ketergantungan jangka panjang terhadap nilai-nilai historis, sebagaimana terlihat baik pada negara berkembang, termasuk Indonesia, maupun pada sistem nilai tukar utama di era euro (Asif dan Frömmel, 2022; Barkoulas et al., 2016). 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* (Hosking & Michael, 1981). *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. Pemodelan ARFIMA seringkali dimanfaatkan dalam berbagai bidang termasuk keuangan, karena sifat *long memory* seringkali terlihat pada data keuangan (volatilitas).

3 12 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 dilakukan pemodelan ARFIMA untuk meramalkan data keuangan terkait Indeks Harga Perdagangan dan memberikan kesimpulan bahwa model ARFIMA baik dalam meramalkan data pada penelitian. Berdasarkan penelusuran yang dilakukan oleh peneliti, belum ditemui penelitian yang membahas tentang peramalan nilai tukar rupiah terhadap *US Dollar* dengan data terbaru menggunakan model ARFIMA. Dengan menggunakan pemodelan ARFIMA pada data nilai tukar rupiah terhadap *US Dollar* pada periode Januari 2023 – Maret 2025 yang kemungkinan besar bersifat *long memory*, penelitian ini memberikan unsur pembeda jika dibandingkan dengan penelitian yang ada sebelumnya. Sehingga penelitian ini dilakukan dengan tujuan menentukan model ARFIMA terbaik untuk meramalkan serta menganalisis hasil peramalan dari data nilai tukar rupiah terhadap *US Dollar*. Penelitian ini diharapkan dapat memberikan kontribusi berupa hasil peramalan yang diharapkan menjadi referensi atau acuan untuk mengambil keputusan yang tepat 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. Komponen penting untuk memahami karakteristik data adalah bentuk pola, secara umum pola data diklasifikasikan ke dalam empat kategori utama, yaitu horizontal, musiman, siklis dan tren (Makridakis, et al., 1999). 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  $\delta$ . 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, ketidakstasioneran data dapat mengganggu analisis dan akurasi model yang akan digunakan sehingga diperlukan proses *differencing*. Selain itu 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  $\lambda$  parameter transformasi dan  $Z_t$  nilai aktual pada waktu ke- $t$ , nilai  $\lambda$  yang dipilih merupakan nilai  $\lambda$  yang diperoleh dengan meminimumkan jumlah kuadrat residual sehingga memiliki varians yang minimum.

Salah satu kasus khusus dalam data runtun waktu adalah adanya karakteristik memori jangka panjang (*long memory*) pada data tersebut. 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, bahkan menyerupai bentuk fungsi hiperbolik (Wei, 2006).

Selain mengidentifikasi proses *long memory* menggunakan plot ACF, terdapat nilai statistik yang dikhawasukan untuk melihat 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 (3).

$$H = \frac{\sum_{j=1}^T (X_j - \bar{X})(Y_j - \bar{Y})}{\sum_{j=1}^T (X_j - \bar{X})^2} \quad (3)$$

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.

1. Jika nilai  $H = 0.5$ , maka menunjukkan karakteristik acak.
2. Jika nilai  $H$  pada data berada pada rentang  $0 < H < 0.5$ , maka menunjukkan karakteristik *short memory*.
3. 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). Dengan menambahkan komponen fraksional pada parameter integrasi, ARFIMA memberikan fleksibilitas yang lebih besar dalam menangani data yang terbukti bersifat *long memory*. Apabila suatu model ARFIMA(p,d,q) dengan  $p$  dan  $q$  adalah bilangan bulan non negatif dan  $0 < d < 0.5$ , maka proses *time series* tersebut menunjukkan sifat *long memory* atau persisten (Wei, 2006). Model ARFIMA(p,d,q) secara umum direpresentasikan pada persamaan (4).

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)a_t \quad (4)$$

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 adalah metode 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 (5).

$$\hat{d} = H - 0.5 \quad (5)$$

Pemodelan ARFIMA pada penelitian ini menggunakan metode *Box-Jenkins* yang melalui beberapa tahapan, yaitu 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 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 estimasi parameter AR(p) dan MA(q) direpresentasikan dalam persamaan (6) dan (7).

$$\hat{\phi}_p = \frac{\sum_{t=p+1}^n Z_{t-1}Z_t}{\sum_{t=p+1}^n Z_{t-1}^2} \quad (6)$$

$$\hat{\theta}_q = \frac{\sum_{t=q+1}^n Z_t a_{t-1}}{\sum_{t=q+1}^n a_{t-1}^2} \quad (7)$$

dengan  $Z_t$  nilai variabel pada waktu  $t$  dan  $a_t$  : white noise atau error term pada waktu ke- $t$ .

Dalam menentukan tingkat signifikansi parameter dalam model ARFIMA(p, d, q) diperlukan standar pengujian. Pada umumnya, nilai  $Z = 1.96$  sering digunakan dalam pengujian hipotesis dua sisi dengan tingkat signifikansi  $\alpha = 0.05$  (5%), 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

1 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 (8) 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*)

$$Q = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (8)$$

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

1 Pengujian *Kolmogorov-Smirnov* digunakan untuk memeriksa apakah residual mengikuti distribusi normal. Pengujian normalitas yang dilakukan direpresentasikan dengan statistik uji pada persamaan (9) dengan hipotesis sebagai berikut.

$H_0$  : Residual berdistribusi normal

$H_1$  : Residual tidak berdistribusi normal

$$D = \text{Sup}_x |S(x) - F_0(x)| \quad (9)$$

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 pada penelitian ini didasarkan pada nilai *Bayesian Information Criterion* (BIC) terkecil. Kriteria pemilihan model BIC menjadi kriteria pemilihan model terbaik, karena kriteria BIC lebih baik dalam memenuhi sifat kesederhanaan dalam mengidentifikasi model (Rahkmawati, et al., 2019). Formulasi nilai BIC dapat dinyatakan pada persamaan (10).

$$BIC = -2 \ln(L) + s \ln(n) \quad (10)$$

$L$  adalah nilai maksimum *likelihood function*,  $s$  banyak parameter dan  $n$  banyak pengamatan.

### 3. METODE PENELITIAN

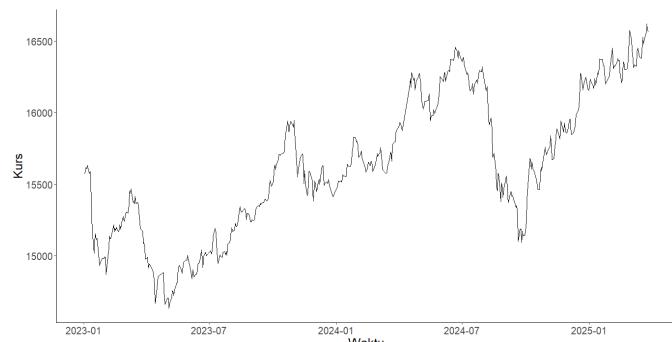
Data yang digunakan pada penelitian adalah data sekunder yang merupakan data harian nilai tukar rupiah terhadap *US Dollar* (USD/IDR), diperoleh melalui website resmi Bank Indonesia untuk periode bulan Januari 2023 sampai dengan bulan Maret 2025 dengan total observasi sebanyak 535. Penelitian ini dilakukan dengan menggunakan *software*/perangkat lunak perhitungan *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.
3. Melakukan pemesikan terhadap kestasioneran data dengan beberapa tahapan sebagai berikut.
  - a) Memeriksa kestasioneran dalam rata-rata dengan menggunakan uji *Augmented Dickey-Fuller* (ADF) yang ditunjukkan pada persamaan (1).
  - b) Memeriksa kestasioneran data dalam ragam, jika data tidak stasioner dalam ragam, maka dilakukan transformasi data dengan menggunakan fungsi *Box-Cox transformation* yang ditunjukkan pada persamaan (2).
4. Mengidentifikasi adanya sifat long memory pada data dengan melihat pola ACF dan menggunakan nilai Hurst (H) yang dapat dihasilkan dari persamaan (3). Apabila pola autokorelasi pada plot ACF menunjukkan penurunan secara perlahan atau membentuk pola hiperbolik, maka data memiliki sifat long memory.

- 6
- 11
- 1
- 8.
5. Menetapkan nilai estimasi nilai  $d$  melalui metode Rescaled Range Statistics (R/S) yang dapat diperoleh dengan menghitung persamaan (5).
6. Melakukan proses differencing menggunakan nilai estimasi  $d$  bernilai pecahan yang telah diperoleh sebelumnya.
7. Membentuk beberapa model ARFIMA dengan beberapa langkah sebagai berikut.
- Identifikasi orde model ARFIMA dengan memperhatikan pola ACF untuk MA( $p$ ) dan PACF untuk AR( $q$ ) pada data yang telah dilakukan *differencing*.
  - Estimasi parameter  $\phi$  dan  $\theta$  pada model tentatif yang telah dibentuk dengan menggunakan metode *Exact Maximum Likelihood* dengan persamaan (6) dan (7).
  - Uji diagnostik model untuk menguji kelayakan model yang meliputi uji asumsi autokorelasi dan normalitas. Pengujian autokorelasi menggunakan *L-Jung Box* dengan persamaan (8), sedangkan uji normalitas menggunakan uji *Kolmogorov Smirnov* dengan persamaan (9).
  - Seleksi model ARFIMA terbaik yang digunakan untuk peramalan didasarkan pada nilai BIC terkecil dengan mengacu pada persamaan (10).
8. Peramalan data untuk 50 periode kedepan dengan menggunakan model ARFIMA terbaik yang telah diperoleh.

#### 4. HASIL DAN PEMBAHASAN

Tahap awal yang perlu dilakukan sebelum melakukan peramalan adalah mengamati pola data, pola data dapat dilihat dari plot *time series* untuk mengidentifikasi pola data yang terbentuk.



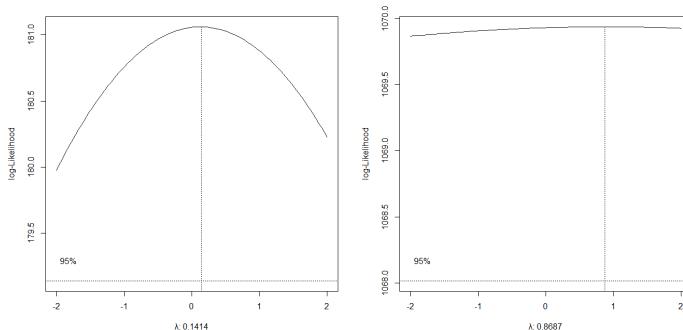
3

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

3

Gambar 2 mengindikasikan adanya tren naik pada data nilai tukar rupiah terhadap US Dollar (USD/IDR), sehingga dapat dikatakan bahwa data tidak stasioner. Selain itu, tidak diitunjukkan adanya pola musiman pada data tersebut jika dilihat secara visual.

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  $\lambda = 0.1414$  yang berarti bahwa data belum stasioner dalam varians, sehingga diperlukan penanganan berupa transformasi. Transformasi dilakukan dengan menstasionerkan data terhadap varians menggunakan persamaan (2).

$$T(Z_t) = \frac{Z_t^{0.1414} - 1}{0.1414} \quad (11)$$

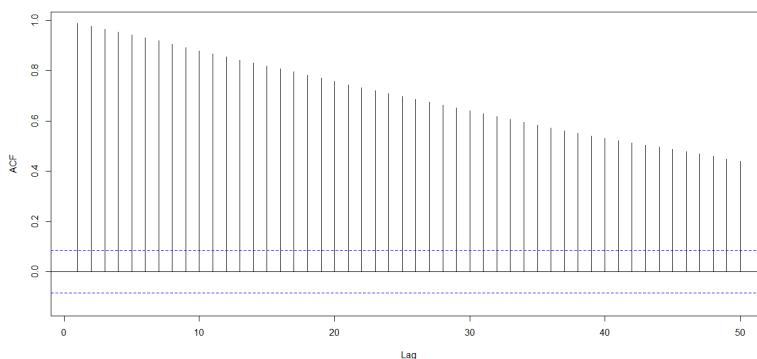
Berdasarkan hasil pemeriksaan yang ditunjukkan pada Gambar 3 (kanan), data yang telah melalui proses transformasi dapat dikatakan telah mencapai kondisi stasioner dalam varians karena memberikan nilai  $\lambda = 0.8687$ , dimana nilai tersebut mendekati 1. Setelah data dinyatakan stasioner terhadap varians, langkah berikutnya adalah melakukan pengecekan stasioneritas data dalam rata-rata menggunakan uji *Augmented Dickey Fuller* (ADF). Proses ini dilakukan dengan menggunakan data hasil transformasi sebelumnya dan menggunakan hipotesis serta statistik uji yang ada pada persamaan (1).

Tabel 1. Uji ADF Data Sesudah Transformasi

	Nilai
<i>Dickey-Fuller</i>	-3.0415
<i>P-value</i>	0.1374

Pada Tabel 1, hasil uji ADF menunjukkan bahwa nilai *p-value* sebesar  $0.1374 > 0.05$  ( $\alpha = 5\%$ ), 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 *short memory differencing* dilakukan dengan  $d$  bernilai bilangan bulat, sedangkan untuk 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 yang mengalami penurunan secara eksponensial, melainkan menurun secara perlahan yang mengidentifikasi 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* pada data sepenuhnya mengacu pada persamaan (3), data dapat dinyatakan bersifat *long memory* jika nilai  $H$  berada pada rentang  $0.5 < H < 1$ .

Tabel 2. Nilai *Hurst*

	Nilai
<i>Simple R/S Hurst Estimation</i>	0.8372489
<i>Corrected R over S Hurst Exponent</i>	0.9952601
<i>Empirical Hurst Exponent</i>	0.9789936
<i>Corrected Empirical Hurst Exponent</i>	0.9530527
<i>Theoretical Hurst Exponent</i>	0.5455964

Berdasarkan Tabel 2, 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 0.8372489. Nilai tersebut berada pada interval  $0.5 < H < 1$  yang menyatakan bahwa data bersifat *long memory* atau memiliki ketergantungan memori jangka panjang. Sehingga berdasarkan karakteristik data nilai tukar rupiah terhadap *US Dollar* (USD/IDR), model ARFIMA merupakan model yang paling sesuai untuk digunakan.

*Rescaled Range Statistics* (R/S) atau nilai *Hurst* ( $H$ ) juga dapat dimanfaatkan untuk mengestimasi parameter pembeda ( $d$ ). Setelah nilai *Hurst* diperoleh, estimasi nilai  $d$  dengan menggunakan metode R/S dapat diperoleh dengan menggunakan persamaan (5).

$$\hat{d} = 0.8372489 - 0.5 = 0.3372489 \quad (12)$$

Nilai estimasi  $d$  ditentukan dengan mengurangkan nilai  $H$  terpilih dengan 0.5, sehingga diperoleh nilai estimasi  $d$  sebesar 0.3372489. 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  $d$  yang sudah diperoleh.

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

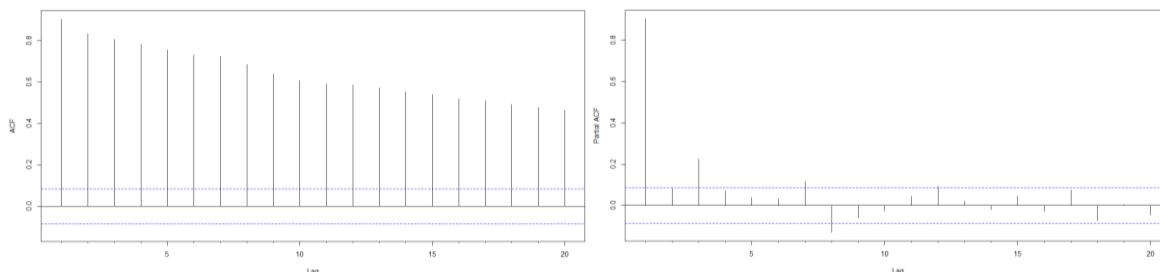
memenuhi kriteria stasioner dalam rata-rata atau masih diperlukan langkah tambahan untuk mengubahnya menjadi stasioner.

Tabel 3. Hasil Uji ADF Data Sesudah *Differencing*

Nilai	
<i>Dickey-Fuller</i>	-3.7752
<i>P-value</i>	0.0202

Pada Tabel 1, hasil uji ADF menunjukkan bahwa nilai *p-value* sebesar  $0.0202 < 0.05$  ( $\alpha = 5\%$ ), 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 0.3372489 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). *Lag* pada plot PACF *cuts off* setelah *lag* 3, dengan mempertimbangkan beberapa kemungkinan model tentatif yang sesuai, maka orde AR(p) yang terbentuk adalah AR(0), AR(1), AR(2), AR(3) dan AR(4). Sehingga secara total terdapat sebanyak 19 model tentatif yang ditunjukkan pada Tabel 4 dan akan dilanjutkan untuk analisis berikutnya.

Tabel 4. 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  $\phi$  dan  $\theta$  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  $d = 0.3372489$  ditunjukkan pada tabel 5.

Tabel 5. Uji Signifikansi Parameter Model Tentatif

No	ARFIMA(p,d,q)	Parameter	SE	Z	Keterangan
1	ARFIMA(0,d,1)	$\hat{\theta}_1 = -0.6446$	0.0293	-22.0129	Signifikan
2	ARFIMA(0,d,2)	$\hat{\theta}_1 = -0.7468$ $\hat{\theta}_2 = -0.3392$ $\hat{\theta}_1 = -0.7399$ $\hat{\theta}_2 = -0.3221$ $\hat{\theta}_3 = -0.2603$	0.0391 0.0383 0.0463 0.0446 0.0441	-19.1173 -8.8522 -15.9861 -7.2219 -5.9081	Signifikan Signifikan Signifikan Signifikan Signifikan
3	ARFIMA(0,d,3)	$\hat{\theta}_1 = 0.9881$ $\hat{\phi}_1 = 0.9946$ $\hat{\theta}_1 = -0.2019$ $\hat{\phi}_1 = 0.1913$ $\hat{\phi}_2 = 0.7930$ $\hat{\theta}_1 = -0.9089$ $\hat{\phi}_1 = 0.9743$ $\hat{\phi}_2 = -0.1792$ $\hat{\phi}_3 = 0.1868$	0.0077 0.0049 0.0688 0.0648 0.0626 0.0418 0.0826 0.0685 0.0502	129.1027 203.5697 -2.9348 2.9535 12.6704 -21.7269 11.8009 -2.6149 3.7224	Signifikan Signifikan Signifikan Signifikan Signifikan Signifikan Signifikan Signifikan Signifikan
4	ARFIMA(1,d,0)				
5	ARFIMA(1,d,1)				
6	ARFIMA(2,d,1)				
7	ARFIMA(3,d,0)				

Dengan kriteria pengambilan keputusan tolak  $H_0$  perhitungan statistik menunjukkan nilai Z hitung ( $|Z|$ ) berada pada  $-1.96 > |Z| > 1.96$ . Berdasarkan Tabel 5, sebanyak 7 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. Uji autokorelasi pada asumsi *white noise* dilakukan untuk mendeteksi korelasi antar nilai residual atau sisaan yang dihasilkan oleh model ARFIMA yang signifikan melalui uji *L-jung Box*. Adapun uji asumsi kenormalan pada residual dapat dilihat melalui uji *Kolmogorov-Smirnov*. Hipotesis dan statistik uji pada pengujian ini mengacu pada persamaan (8) dan (9).

Tabel 6. Uji Diagnostik Model Terpilih

No	Model ARFIMA	P-value		Keterangan
		L-Jung Box	KS	
1	ARFIMA(0,d,2)	0.2834	0.0510	Acak dan Normal
2	ARFIMA(0,d,3)	0.7991	0.0769	Acak dan Normal
3	ARFIMA(1,d,0)	0.2219	0.1216	Acak dan Normal
4	ARFIMA(1,d,1)	0.7102	0.0918	Acak dan Normal
5	ARFIMA(2,d,1)	0.8423	0.1053	Acak dan Normal
6	ARFIMA(3,d,0)	0.9926	0.0857	Acak dan Normal

Berdasarkan Tabel 6, hasil pengujian asumsi residual menunjukkan bahwa model ARFIMA(0,d,2), ARFIMA(0,d,3), ARFIMA(1,d,0), ARFIMA(1,d,1), ARFIMA(2,d,1) dan ARFIMA(3,d,0) dengan nilai estimasi  $d = 0.3372489$  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 *Bayesian Information Criterion* (BIC) terkecil. Nilai BIC untuk setiap model tentatif yang terbentuk dengan nilai estimasi  $d = 0.3371625$  pada data nilai tukar rupiah terhadap *US Dollar* (USD/IDR) ditunjukkan pada Tabel 7.

Tabel 7. Model ARFIMA Terbaik

No	Model ARFIMA	BIC
1	ARFIMA(0,d,2)	4525.62
2	ARFIMA(0,d,3)	4504.44
3	ARFIMA(1,d,0)	4391.07

4	ARFIMA(1,d,1)	4390.83
5	<b>ARFIMA(2,d,1)</b>	4387.69
6	ARFIMA(3,d,0)	4387.76

Tabel 7 menunjukkan bahwa model ARFIMA(2,d,1) dengan nilai estimasi  $d = 0.3372489$  memiliki nilai 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:

$$(1 - 0.191338B - 0.792988B^2)(1 - B)^{0.3372489}Z_t = (1 + 0.908902B)a_t \quad (13)$$

Berdasarkan model terbaik tersebut, langkah selanjutnya yang dilakukan adalah melakukan proses peramalan (forecasting) untuk memproyeksikan nilai tukar rupiah terhadap *US Dollar* (USD/IDR) untuk beberapa periode berikutnya. Adapun hasil dari peramalan selama 50 periode ke depan disajikan pada Gambar 6.



Gambar 6. Pergerakan Data Asli dan Hasil Peramalan

Hasil peramalan menunjukkan adanya tren penurunan (penguatan) nilai yang berlangsung secara bertahap. Pola penurunan ini konsisten dengan karakteristik model ARFIMA, yang secara khusus dikembangkan untuk menganalisis data dengan sifat *long memory* atau memori panjang. Pengaruh perubahan pergerakan nilai tukar rupiah terhadap *US Dollar* (USD/IDR) yang menurun secara signifikan (menguat) pada periode di masa lalu tersebut menjadi suatu hal yang berpengaruh terhadap hasil peramalan di masa depan.

## 5. KESIMPULAN

Data nilai tukar rupiah terhadap *US Dollar* (USD/IDR) terbukti bersifat *long memory* berdasarkan nilai Hurst yang sebesar 0.8372489, sehingga model ARFIMA sesuai untuk mengatasi kondisi karakteristik data penelitian. Model ARFIMA terbaik yang terbentuk adalah ARFIMA(2,0.3372489,1) dengan nilai BIC 4387.69 dan persamaan:

$$(1 - 0.191338B - 0.792988B^2)(1 - B)^{0.3372489}Z_t = (1 + 0.908902B)a_t$$

Hasil peramalan menggunakan model ARFIMA terbaik menunjukkan potensi penguatan nilai rupiah di masa depan, penguatan ini didorong oleh faktor perdagangan internasional, pertumbuhan ekonomi dan suku bunga. Faktor eksternal seperti kebijakan *The Fed* juga perlu terus dipantau karena dapat memengaruhi dinamika nilai tukar di masa depan.

## DAFTAR PUSTAKA

- Ardesfira, G. et al., 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 LongMemory in Exchange Rates and Its Implications forThe Adaptive Market Hypothesis. *Physica A: Statistical Mechanics and its Applications*, Vol. 593.
- Azan, A. N. A. M., Matoto, N. F. A. M. Z. & Mah, P. J. W., 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*, pp. 22-33.
- Barkoulas, J. T., Barilla, A. G., & Wells, W., 2016. Long-memory Exchange Rate Dynamics in The Euro Era. *Chaos, Solitons & Fractals*, Vol. 86.
- Faustina, T. A., 2023. Nilai Tukar Rupiah Menguat: Bagaimana Dampaknya pada Ekonomi Lokal. *Jurnal Pendidikan dan Sosial Humaniora*, pp. 127-135.
- Granger, C. W. J. & Joyeux, R., 1980. An Introduction to Long-Memory Time Series Models and Fractional Differencing. *Journal of Time Series Analysis*, pp. 15-29.
- Hartini, D., 2016. Penerapan Model ARFIMA (Autoregressive Fractionally Integrated Moving Average) Dalam Prakiraan Data Suku Bunga PUAB (Pasar Uang Antar Bank).
- Hasan, I. K., Janur, M. & Nurwan, 2023. Penerapan Model Arfima-Garch Menggunakan Variasi Estimasi Parameter Pembeda D Pada Data Long Memory. *Jurnal Statistika*, pp. 474-485.
- Hosking & Michael, J. R., 1981. Fractional Differencing. *Biometrika*, pp. 165-176.
- Imani, N. D. L., Tarno & Saputra, B. A., 2023. Prediksi Harga Daging Sapi di Kabupaten Brebes Menggunakan Pemodelan ARFIMA dengan Efek GARCH. *Jurnal Gaussian*, Volume 12, pp. 570-580.
- Makridakis, S. G., Steven, C. W. & Victor, E. M., 1999. *Metode dan Aplikasi Peramalan*. 2nd ed. Jakarta: Erlangga.
- Melani, V. D., Miftahuddin & Subianto, M., 2022. Seleksi Model ARFIMA-GPH dan Intervensi Multi Input pada Indeks Harga Perdagangan Besar Indonesia. *Jurnal Gaussian*, Volume 11, pp. 163-172.
- Rahkmawati, Y., Sumertajaya, I. M. & Aidi, M. N., 2019. Evaluation of Accuracy in Identification of ARIMA Models Based on Model Selection Criteria for Inflation Forecasting with the TSClust Approach. *International Journal of Scientific and Research Publications*, pp. 439-443.
- Rahmawati, A., Maruddani, D. A. I. & Hoyyi, A., 2017. Structural Vector Autoregressive untuk Analisis Dampak Shock Nilai Tukar terhadap Dolar Amerika Serikat pada Indeks Harga Saham Gabungan. *Jurnal Gaussian*, Volume 6, pp. 291-302.
- Rismawati, N. & Sugiman, 2022. Long Memory Volatility Model dengan ARFIMA-HYGARCH untuk Meramalkan Return Indeks Harga Saham Gabungan (IHSG). *UNNES Journal of Mathematics*.
- Safitri, D., Mustafid, Ispriyanti, D. & Sugito, 2019. Gold Price Modeling in Indonesia using ARFIMA Method. *IOP Conf. Series: Journal of Physics*, pp. 1-11.
- Wei, W. W. S., 2006. *Time Series Analysis Univariate and Multivariate Methods Second Edition*. New York: Pearson Addison Wesley.
- Winanti, G. L., Ispriyanti, D. & Sugito, 2023. Pemodelan Indeks Harga Perdagangan Besar (IHPB) Sektor Ekspor Menggunakan ARFIMA-GARCH. *Jurnal Gaussian*, Volume 12, pp. 52-60.