

Peramalan Nilai Tukar Rupiah Terhadap Dolar Amerika: Metode ARFIMA dengan LWE

Nasywa Syaharani*, Marizsa Herlina

Prodi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Islam Bandung, Indonesia.

nasywasyaharani1104@gmail.com, marizsa.herlina@unisba.ac.id

Abstract. The fluctuation of the Rupiah exchange rate against the US Dollar significantly impacts economic stability and investment decisions. This study aims to model and forecast the exchange rate using the Autoregressive Fractionally Integrated Moving Average (ARFIMA) method, which captures the long memory characteristics of time series data. The fractional differencing parameter d is estimated using the Local Whittle Estimator (LWE), a semi-parametric method that is efficient in detecting long-range dependence. The data used consists of daily midpoint exchange rates from 2021 to 2024, totaling 979 observations. The estimation result yields $d=0.4899$, indicating a stationary process with long memory properties. The best-selected model is ARFIMA(1, 0.4899, 2), where all parameters are statistically significant and the residuals fulfill the white noise assumption. The forecasting results show a fluctuating pattern followed by a gradual downward trend toward stability. These findings suggest that the ARFIMA model is effective for long-term forecasting and can serve as a reference for economic decision-making.

Keywords: *ARFIMA, Local Whittle Estimator, Long Memory.*

Abstrak. Fluktuasi nilai tukar Rupiah terhadap Dolar Amerika memiliki dampak signifikan terhadap stabilitas ekonomi dan keputusan investasi. Penelitian ini bertujuan untuk memodelkan dan meramalkan nilai tukar menggunakan metode *Autoregressive Fractionally Integrated Moving Average* (ARFIMA), yang mampu menangkap karakteristik *long memory* pada data deret waktu. Estimasi parameter fraksional d dilakukan dengan pendekatan *Local Whittle Estimator* (LWE) yang efisien dalam mendeteksi memori jangka panjang. Data yang digunakan adalah nilai tukar kurs tengah harian Rupiah terhadap Dolar Amerika dari tahun 2021 hingga 2024 sebanyak 979 observasi. Berdasarkan hasil estimasi, diperoleh nilai $d=0,4899$ yang menunjukkan sifat stasioner dengan *long memory*. Model terbaik yang terpilih adalah ARFIMA(1, 0.4899, 2) dengan seluruh parameter signifikan dan residual yang memenuhi asumsi *white noise*. Hasil peramalan menunjukkan pola fluktuatif dengan tren penurunan bertahap menuju kestabilan. Temuan ini menegaskan bahwa model ARFIMA efektif digunakan dalam peramalan jangka panjang untuk mendukung pengambilan keputusan ekonomi.

Kata Kunci: *ARFIMA, Local Whittle Estimator, Long Memory.*

A. Pendahuluan

Perubahan kurs memiliki implikasi langsung terhadap perdagangan internasional, inflasi, investasi, dan daya saing ekspor. Ketidakstabilan nilai tukar dapat mempersulit perencanaan ekonomi pemerintah dan meningkatkan risiko bagi pelaku usaha yang bergantung pada transaksi valuta asing. Dalam beberapa tahun terakhir, fluktuasi nilai tukar yang semakin tajam menuntut adanya pendekatan prediktif yang lebih akurat dan responsif terhadap pola jangka panjang. Oleh karena itu, kemampuan memodelkan dan meramalkan nilai tukar secara akurat sangat diperlukan, baik oleh pemerintah dalam merumuskan kebijakan ekonomi, maupun oleh pelaku pasar dalam pengambilan keputusan investasi. Berbagai metode peramalan telah digunakan untuk memodelkan pergerakan nilai tukar, salah satunya adalah ARIMA yang cukup populer karena mampu menangani data tidak stasioner melalui proses *differencing*. Namun demikian, ARIMA memiliki keterbatasan dalam mengakomodasi fenomena *long memory*, yaitu ketergantungan jangka panjang dalam data deret waktu yang umum terjadi pada variabel-variabel ekonomi seperti nilai tukar. Untuk itu, dikembangkanlah model ARFIMA, yang memungkinkan penggunaan *differencing* fraksional guna menangkap dinamika jangka panjang secara lebih presisi (Mahmad Azan et al., 2021).

Salah satu tantangan dalam penggunaan ARFIMA adalah estimasi parameter *differencing* fraksional d yang akurat. Penelitian ini menggunakan metode *Local Whittle Estimator* (LWE) sebagai pendekatan semiparametrik yang beroperasi pada domain frekuensi rendah. LWE dipilih karena mampu menghasilkan estimasi parameter yang konsisten dan efisien, bahkan pada data yang bersifat non-stasioner, volatil, dan berdimensi panjang. Beberapa studi terdahulu menunjukkan keunggulan LWE dalam memodelkan data keuangan dan nilai tukar yang kompleks, menjadikannya pilihan yang relevan untuk digunakan dalam konteks penelitian ini (Baillie et al., 2014).

Penelitian ini bertujuan untuk memodelkan dan meramalkan nilai tukar Rupiah terhadap Dolar Amerika menggunakan model ARFIMA dengan estimasi parameter fraksional melalui metode Local Whittle. Dengan pendekatan ini, diharapkan diperoleh model peramalan yang tidak hanya akurat, tetapi juga mampu menangkap struktur memori jangka panjang dalam data, sehingga dapat menjadi acuan dalam pengambilan keputusan ekonomi baik oleh pemerintah, pelaku usaha, maupun investor.

B. Metode

Penelitian ini menggunakan data sekunder berupa nilai tukar kurs tengah harian Rupiah terhadap Dolar Amerika Serikat yang diperoleh dari situs resmi Bank Indonesia. Data yang digunakan mencakup periode 4 Januari 2021 hingga 31 Desember 2024, dengan jumlah total 979 observasi. Nilai tukar kurs tengah dihitung sebagai rata-rata antara kurs beli dan kurs jual, dan digunakan sebagai representasi pergerakan nilai tukar selama periode pengamatan.

Stasioneritas

Stasioneritas penting dalam analisis deret waktu agar estimasi parameter konsisten dan hasil peramalan stabil. Pengujiannya dilakukan dengan Augmented Dickey-Fuller (ADF) test, yang mendeteksi unit root dan mengatasi autokorelasi melalui penambahan lag dalam model (Maitra & Politis, 2024). Bentuk umum persamaan ADF adalah sebagai berikut:

$$\Delta Y_t = \alpha + \beta t + \gamma Y_{t-1} + \sum_{i=1}^p \delta_i \Delta Y_{t-1} + \varepsilon_t \quad (1)$$

Keterangan:

Y_t	: Nilai Deret Waktu pada Waktu Ke-T,
t	: Tren Waktu,
α	: Intersep (Konstanta),
γ	: Koefisien yang Diuji untuk Stasioneritas,
δ_i	: Parameter Lag dari Perbedaan Pertama,
ε_t	: Error Term yang Diasumsikan White Noise,
P	: Jumlah Lag Optimal.

Model Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA(p, d, q) diperluas dari model ARMA dengan menambahkan proses pembedaan (*differencing*) untuk menangani data deret waktu yang tidak stasioner. Parameter d menunjukkan jumlah *differencing* yang diperlukan untuk mencapai stasioneritas. Bentuk umum model ARIMA(p, d, q) adalah:

$$\phi(B)(1 - B)^d Y_t = \theta(B)\varepsilon_t \quad (2)$$

di mana $(1 - B)^d$ merupakan operator differencing orde d (Brockwell & Davis, 2016).

Long Memory

Dalam analisis deret waktu, *long memory* menggambarkan proses di mana autokorelasi menurun secara lambat dan tetap signifikan pada lag besar, menunjukkan ketergantungan jangka panjang antar observasi. Karakteristik ini sering ditemukan dalam data ekonomi dan keuangan, sehingga memerlukan model yang mampu menangani struktur memori tersebut secara tepat (Silverberg & Verspagen, 1999).

Model Autoregressive Fractionally Integrated Moving Average (ARFIMA)

Model ARFIMA merupakan pengembangan dari ARIMA yang memungkinkan derajat integrasi d bernilai pecahan untuk menangani data deret waktu dengan *long memory* (Hosking, 1981).

Secara umum, model ARFIMA(p, d, q) pada proses $\{Y_t\}$ dapat dituliskan sebagai berikut:

$$\phi(B)(1 - B)^d Y_t = \theta(B)\varepsilon_t \quad (3)$$

dengan $\phi(B)$ dan $\theta(B)$ masing-masing menyatakan polinomial *autoregressive* dan *moving average*, $(1 - B)^d$ adalah operator *differencing* fraksional dan ε_t merupakan *white noise*.

Nilai parameter d dalam model ARFIMA menentukan sifat memori dan stasioneritas proses. Jika $0 < d < 0.5$, maka proses bersifat stasioner dan menunjukkan *long memory*. Pada rentang $0.5 \leq d < 1$, proses menjadi tidak stasioner, tetapi masih memiliki sifat *mean-reverting*. Sementara itu, jika $d \geq 1$, proses bersifat non-stasioner dan tidak *mean-reverting* (Granger, 2002).

Fractional Integrated

Fractional integration merupakan dasar model ARFIMA yang memungkinkan nilai differencing d berbentuk pecahan, tidak seperti ARIMA yang terbatas pada bilangan bulat. Hal ini membuat ARFIMA lebih unggul dalam menangkap karakteristik *long memory* pada deret waktu (Granger, 2002). Operator *differencing* fraksional $(1 - B)^d$ untuk nilai d non-integer didefinisikan melalui ekspansi deret binomial tak hingga sebagai berikut:

$$\begin{aligned} (1 - B)^d &= \sum_{k=0}^{\infty} \binom{d}{k} (-1)^k B^k \\ &= 1 - dB + \frac{d(d-1)}{2!} B^2 - \frac{d(d-1)(d-2)}{3!} B^3 + \dots \end{aligned} \quad (4)$$

Local Whittle Estimator (LWE)

Local Whittle Estimator adalah metode semiparametrik berbasis domain frekuensi yang digunakan untuk mengestimasi parameter *differencing fraksional* d pada deret waktu *long memory*. Berbeda dengan pendekatan parametrik, LWE tidak memerlukan spesifikasi lengkap model ARMA dan hanya menggunakan informasi spektral di sekitar frekuensi nol melalui fungsi log-likelihood lokal berikut:

$$Q(d) = \log \left(\frac{1}{m} \sum_{j=1}^m \lambda_j^{2d} I(\lambda_j) \right) - 2d \cdot \frac{1}{m} \sum_{j=1}^m \log(\lambda_j) \quad (5)$$

Keterangan:

$I(\lambda_j)$: periodogram pada frekuensi (λ_j) ,

λ_j : frekuensi Fourier, dengan $j = 1, 2, \dots, m$,

m : jumlah frekuensi rendah yang digunakan atau *bandwidth* ($m = T^\alpha$),

T : panjang deret waktu.

Keunggulan utama LWE adalah robust terhadap spesifikasi model jangka pendek dan efisien untuk estimasi parameter d dalam aplikasi seperti peramalan nilai tukar jangka panjang (Phillips & Shimotsu, 2004).

Estimasi ini didasarkan pada periodogram, yang merepresentasikan distribusi spektral dari variansi deret waktu. Secara umum, periodogram dari suatu deret waktu diskrit $\{Y_t\}_{t=1}^T$ didefinisikan sebagai:

$$I(\lambda) = \frac{1}{2\pi T} \left| \sum_{t=1}^T Y_t e^{-i\lambda t} \right|^2 \quad (6)$$

dimana:

$I(\lambda)$: nilai periodogram pada frekuensi λ ,

$e^{-i\lambda t}$: komponen eksponensial kompleks,

$\lambda \in (0, \pi)$: frekuensi angular, biasanya diambil sebagai $\lambda_j = \frac{2\pi j}{T}$ untuk $j = 1, 2, \dots, [T/2]$.

Estimasi Parameter d (Long Memory)

Estimasi parameter d dilakukan untuk mengukur tingkat memori jangka panjang pada deret waktu. Dalam penelitian ini, digunakan metode *Local Whittle Estimator* yang bersifat semiparametrik dan berbasis domain frekuensi. Estimasi dilakukan dengan meminimalkan fungsi objektif berikut:

$$\hat{d} = \arg \min_d \left\{ \log \left(\frac{1}{m} \sum_{j=1}^m \lambda_j^{2d} I(\lambda_j) \right) - 2d \cdot \frac{1}{m} \sum_{j=1}^m \log(\lambda_j) \right\} \quad (7)$$

Estimasi Parameter AR (p) dan MA (q)

Setelah parameter d diperoleh, dilakukan estimasi parameter ϕ dan θ pada model ARFIMA dengan pendekatan Maximum Likelihood Estimation (MLE). Metode ini bertujuan untuk menemukan nilai parameter yang memaksimalkan fungsi likelihood dari model, dengan asumsi residual $\varepsilon_t \sim \mathcal{N}(0, \sigma_a^2)$ dan bersifat independen. Fungsi log-likelihood-nya gabungan dari residual hingga waktu n dituliskan sebagai:

$$\ln L(\phi, \theta, \sigma_a^2) = -\frac{n}{2} \ln(2\pi\sigma_a^2) - \frac{1}{2\sigma_a^2} \sum_{t=1}^n \varepsilon_t^2 \quad (8)$$

Estimasi parameter dilakukan dengan memaksimalkan fungsi log-likelihood tersebut terhadap ϕ dan θ . Untuk model AR(1), nilai parameter ϕ dapat diestimasi secara eksplisit menggunakan pendekatan Ordinary Least Squares (OLS) sebagai berikut:

$$\hat{\phi} = \frac{\sum_{t=2}^n Y_t Y_{t-1}}{\sum_{t=2}^n Y_{t-1}^2} \quad (9)$$

Sedangkan untuk MA(1), karena residual ε_t tidak diketahui secara langsung, estimasi parameter θ tidak dapat diperoleh secara eksplisit dan harus menggunakan metode numerik (Brockwell & Davis, 2016). Namun, dalam literatur tersedia pendekatan awal untuk estimasi θ sebagai:

$$\hat{\theta} \approx \frac{\sum_{t=2}^n \varepsilon_t \varepsilon_{t-1}}{\sum_{t=2}^n \varepsilon_t^2} \quad (10)$$

White Noise

Dalam analisis deret waktu, *white noise* merujuk pada residual yang acak, tidak berpola, dan tidak berkorelasi antar waktu. Secara matematis, residual $\varepsilon_t \sim WN(0, \sigma^2)$. Residual yang bersifat white noise menandakan bahwa model telah menangkap seluruh pola dalam data. Untuk menguji ada tidaknya autokorelasi pada residual, digunakan uji Ljung-Box dengan menghitung statistik Q sebagai berikut:

$$Q = n(n+2) \sum_{k=1}^h \frac{\hat{\rho}_k^2}{n-k} \quad (11)$$

Keterangan:

- n : ukuran sampel,
- h : jumlah lag yang diuji,
- $\hat{\rho}_k$: estimasi autokorelasi pada lag ke-k.

Jika nilai p-value dari statistik Q lebih kecil dari tingkat signifikansi α , maka H_0 ditolak, yang berarti model belum sepenuhnya menangkap struktur data yang ada. Oleh karena itu, pemeriksaan terhadap sifat white noise menjadi langkah penting dalam validasi model deret waktu (Moffat & Akpan, 2019).

Pemilihan Model Terbaik

Dalam pemilihan model ARFIMA yang digunakan untuk peramalan, kriteria yang umum digunakan adalah *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC) (Box et al., 2008). AIC dihitung dengan rumus:

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

dimana k adalah jumlah parameter ($p + q + 1$) dan L adalah nilai likelihood maksimum. Sementara BIC memperhitungkan jumlah observasi (n):

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

Model dengan nilai AIC atau BIC terkecil dipilih sebagai model terbaik.

Pada penelitian ini, proses analisis data digunakan dengan bantuan software R dengan tahapan analisis sebagai berikut:

1. Mendeskripsikan data nilai tukar Rupiah terhadap Dolar Amerika secara statistik deskriptif.
2. Mengeksplorasi pola tren dan fluktuasi melalui plot deret waktu.
3. Menguji kestasioneran data menggunakan **ADF**. Jika tidak stasioner dalam variansi, dilakukan transformasi **Box-Cox**; jika tidak stasioner dalam rata-rata, dilakukan **differencing**. Nilai d untuk *long memory* diestimasi menggunakan metode **Local Whittle Estimator (LWE)**.
4. Mengidentifikasi *long memory* melalui **plot ACF**.
5. Melakukan pemodelan **ARFIMA**:
 - a. Estimasi parameter d dengan LWE
 - b. Penentuan ordo (p,q) dari ACF dan PACF
 - c. Estimasi parameter dengan **MLE**
 - d. Uji signifikansi parameter
 - e. Diagnostik residual menggunakan **uji Ljung-Box**
 - f. Pemilihan model terbaik berdasarkan **AIC** dan **BIC**
6. Meramalkan nilai tukar satu periode ke depan menggunakan model ARFIMA terpilih.


C. Hasil Penelitian dan Pembahasan Stasioneritas

Tabel 1. Hasil Uji Augmented Dickey-Fuller

Statistik ADF	p-value
-3,2968	0,07123

Berdasarkan Tabel 1, diperoleh nilai statistik ADF sebesar -3,2968 dan p-value sebesar 0,07123. Karena nilai p-value lebih besar dari taraf signifikansi 5% ($\alpha = 0,05$), maka H_0 tidak dapat ditolak, yang berarti bahwa data tidak stasioner secara statistik.

Identifikasi *Long Memory*



Gambar 1. Plot ACF Nilai Tukar Rupiah

Berdasarkan Gambar 2, nilai autokorelasi menurun secara perlahan dan tidak langsung menuju nol, menunjukkan pola hiperbolik yang mengindikasikan adanya *long memory* dalam data nilai tukar. Oleh karena itu, model ARFIMA dipilih karena mampu menangani *differencing* fraksional. Estimasi parameter d akan dibahas pada subbab berikut menggunakan metode *Local Whittle Estimator*.


Menentukan Parameter d dengan *Local Whittle Estimator*

Tabel 2. Hasil Nilai d dengan Metode LWE

Metode Estimasi	Nilai d
LWE	0,4899

Berdasarkan Tabel 2, diperoleh estimasi parameter *differencing* fraksional sebesar $d=0,4899$. Nilai ini berada dalam rentang $0 < d < 0,5$, yang mengindikasikan bahwa data bersifat stasioner dengan memori jangka panjang (*long memory*). Nilai d yang mendekati 0,5 menunjukkan adanya penurunan autokorelasi yang lambat, sehingga mendukung penggunaan model ARFIMA sebagai pendekatan yang tepat dalam peramalan nilai tukar jangka panjang.

Menentukan Model Arfima Berdasarkan Plot ACF dan PACF



Gambar 2. Plot ACF & PACF Nilai Tukar Rupiah *Fractional Differencing*

Berdasarkan Gambar 4, plot ACF dan PACF terhadap data yang telah dilakukan *fractional differencing* menunjukkan satu lag signifikan pada masing-masing plot. ACF mengarah pada komponen MA(1), sementara PACF mengindikasikan komponen AR(1). Dengan estimasi $d=0,4899$, ditentukan lima model tentatif ARFIMA sebagai kandidat awal untuk proses pemodelan.

Estimasi Parameter Model ARFIMA (p,d,q)

Tabel 3. Hasil Estimasi Parameter Model ARFIMA

Model	Parameter	Estimate	Std. Error	Z-value	P-value	Signifikan
ARFIMA(1, d, 0)	ϕ_1	0.8716	0.0202	43.15	< 0.001	Signifikan
ARFIMA(0, d, 1)	θ_1	0.6852	0.0201	34.10	< 0.001	Signifikan
ARFIMA(1, d, 1)	ϕ_1	0.9422	0.0194	48.56	< 0.001	Signifikan
	θ_1	-0.2496	0.0516	-4.83	< 0.001	Signifikan
ARFIMA(0, d, 2)	θ_1	0.8432	0.0295	28.58	< 0.001	Signifikan
	θ_2	0.4388	0.0285	15.40	< 0.001	Signifikan
ARFIMA(1, d, 2)	ϕ_1	0.9788	0.0125	78.28	< 0.001	Signifikan
	θ_1	-0.2536	0.0373	-6.80	< 0.001	Signifikan
	θ_2	-0.2170	0.0375	-5.79	< 0.001	Signifikan

Hasil estimasi parameter dari lima model ARFIMA yang ditampilkan pada Tabel 3 menunjukkan bahwa seluruh parameter signifikan, dengan nilai p-value mendekati nol. Artinya, semua komponen dalam kedua model (AR dan MA) berkontribusi secara signifikan terhadap model.

Pengujian Diagnostik Model

Tabel 4. Uji White Noise

Model	Uji White Noise (p-value)
ARFIMA(1, 0.4899,0)	2.093e-10
ARFIMA(0, 0.4899,1)	< 2.2e-16
ARFIMA(1, 0.4899,1)	6.414e-06
ARFIMA(0, 0.4899,2)	< 2.2e-16
ARFIMA(1, 0.4899,2)	0.227

Berdasarkan uji Ljung-Box, residual model ARFIMA(1, 0.4899, 2) tidak menunjukkan autokorelasi karena nilai p-value lebih besar dari 0,05. Hal ini mengindikasikan bahwa residual bersifat *white noise*, sehingga model layak digunakan untuk peramalan nilai tukar Rupiah terhadap Dolar Amerika.

Model Terbaik

Tabel 5. Model Terbaik AIC dan BIC

Model	AIC	BIC
ARFIMA(1, 0.4899,2),	10674.62	10699.06

Berdasarkan Tabel 5, model ARFIMA(1, 0.4899, 2) dipilih sebagai model terbaik karena memiliki nilai AIC dan BIC paling kecil, yaitu masing-masing sebesar 10674,62 dan 10699,06. Seluruh parameter dalam model ini signifikan, sehingga model dianggap mampu merepresentasikan struktur data dengan baik untuk keperluan peramalan nilai tukar Rupiah terhadap Dolar Amerika.

Persamaan umum model ARFIMA yang digunakan adalah:

$$(1 - \phi_1 B)(1 - B)^{0,4899} Y_t = (1 + \theta_1 B + \theta_2 B^2) \varepsilon_t \quad (14)$$

Dengan hasil estimasi parameter:

$$\begin{aligned} (1 - 0,9788B)(1 - B)^{0,4899} Y_t = \\ (1 - 0,2536B - 0,2170B^2) \varepsilon_t \end{aligned} \quad (15)$$

Nilai $(1 - B)^{0,4899}$ menggambarkan memori jangka panjang dalam deret waktu dijabarkan sebagai berikut:

$$\begin{aligned} (1 - B)^{0,4899} = \\ 1 - 0,4899B - 0,2450B^2 - 0,0817B^3 \end{aligned} \quad (16)$$

Proses *differencing* fraksional dikombinasikan dengan komponen AR menghasilkan transformasi:

$$(1 - 0,9788B)(1 - B)^{0,4899} Y_t = Z_t \quad (17)$$

Kemudian, deret baru Z_t dimodelkan dengan komponen MA sebagai berikut:

$$Z_t = \varepsilon_t - 0,2536\varepsilon_{t-1} - 0,2170\varepsilon_{t-2} \quad (18)$$

Sehingga bentuk lengkap dari model ARFIMA(1, 0.4899, 2) adalah:


$$\begin{aligned} (1 - 0,9788B)(1 - B)^{0,4899} Y_t = \\ \varepsilon_t - 0,2536\varepsilon_{t-1} - 0,2170\varepsilon_{t-2} \end{aligned} \quad (19)$$

Prediksi

Tabel 6. Prediksi Nilai Tukar Rupiah Terhadap Dolar Amerika

Periode	Prediksi <i>Differencing</i>	Prediksi dalam Rupiah
T+1	68,0263	16230,03
T+2	87,8974	16317,92
T+3	85,8315	16403,76
⋮	⋮	
T+198	-7.8801	18901,99
T+199	-7.9108	18894,08
T+200	-7.9408	18886,14

Hasil peramalan menunjukkan bahwa nilai tukar mengalami kenaikan awal, kemudian menurun secara bertahap dan stabil di akhir periode prediksi. Pola ini mencerminkan bahwa model ARFIMA berhasil menangkap karakteristik *long memory*, di mana pergerakan nilai tukar dipengaruhi oleh data historis. Oleh karena itu, model ini relevan digunakan untuk peramalan jangka panjang.



Gambar 5. Plot Nilai Tukar dan Hasil Prediksi ARFIMA

Gambar 5 menunjukkan bahwa data aktual bersifat fluktuatif, sedangkan prediksi model ARFIMA memperlihatkan kenaikan awal yang diikuti penurunan bertahap menuju kestabilan. Pola ini konsisten dengan hasil tabel dan menunjukkan bahwa ARFIMA mampu menangkap efek jangka panjang serta menghasilkan proyeksi yang realistis sesuai kondisi ekonomi makro.

D. Kesimpulan

Analisis terhadap data nilai tukar Rupiah terhadap Dolar Amerika periode 2021–2024 menunjukkan bahwa model ARFIMA merupakan pendekatan yang sesuai untuk menangkap karakteristik *long memory* dalam data. Estimasi parameter *differencing* fraksional menggunakan *Local Whittle Estimator* menghasilkan nilai d dalam rentang stasioner dengan memori jangka panjang. Model terbaik yang diperoleh adalah ARFIMA(1, 0.4899, 2), dengan parameter signifikan dan residual memenuhi asumsi white noise. Hasil peramalan menunjukkan tren penurunan yang stabil menuju nilai konvergen, yang mengindikasikan bahwa model ARFIMA efektif digunakan dalam peramalan deret waktu ekonomi jangka panjang.

Ucapan Terimakasih

Peneliti mengucapkan terima kasih kepada Ibu Marizsa Herlina, S.Si., M.Sc., selaku dosen pembimbing, atas bimbingan dan saran yang telah diberikan selama proses penelitian ini. Peneliti juga mengucapkan terima kasih kepada semua pihak yang telah membantu hingga penelitian ini dapat diselesaikan.

Daftar Pustaka

- Baillie, R. T., Kapetanios, G., & Papailias, F. (2014). Bandwidth selection by cross-validation for forecasting long memory financial time series. *Journal of Empirical Finance*, 29, 129–143. <https://doi.org/10.1016/j.jempfin.2014.04.002>
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2008). *Time Series Analysis* (5th ed.). Wiley. <https://doi.org/10.1002/9781118619193>

- Brockwell, P. J., & Davis, R. A. (2016). Introduction to Time Series and Forecasting. In *Journal of the American Statistical Association* (Vol. 92, Issue 440). Springer International Publishing. <https://doi.org/10.1007/978-3-319-29854-2>
- Granger, C. W. J. (2002). *Long Memory , Volatility , Risk and Distribution*. October.
- Hosking. (1981). *Hosking_1981_Fractional_differencing.pdf* (pp. 165–176).
- Mahmad Azan, A. N. A., Mohd Zulkifly Mototo, N. F. A., & Mah, P. J. W. (2021). The Comparison between ARIMA and ARFIMA Model to Forecast Kijang Emas (Gold) Prices in Malaysia using MAE, RMSE and MAPE. *Journal of Computing Research and Innovation*, 6(3), 22–33. <https://doi.org/10.24191/jcrinn.v6i3.225>
- Maitra, S., & Politis, D. N. (2024). Prepivoted Augmented Dickey-Fuller Test with Bootstrap-Assisted Lag Length Selection. *Stats*, 7(4), 1226–1244. <https://doi.org/10.3390/stats7040072>
- Moffat, I. U., & Akpan, E. A. (2019). White Noise Analysis: A Measure of Time Series Model Adequacy. *Applied Mathematics*, 10(11), 989–1003. <https://doi.org/10.4236/am.2019.1011069>
- Oktaviani, N. K., & Rifai, N. A. K. (2024). Pemodelan ARFIMA dengan Estimasi Parameter Pembeda Menggunakan Metode Geweke Porter-Hudak. *Jurnal Riset Statistika*, 11–20. <https://doi.org/10.29313/jrs.v4i1.3835>
- Phillips, P. C. B., & Shimotsu, K. (2004). Local whittle estimation in nonstationary and unit root cases. *Annals of Statistics*, 32(2), 656–692. <https://doi.org/10.1214/009053604000000139>
- Sahwa Chanigia Viqri, Z., & Kurniati, E. (n.d.). *Perbandingan Penerapan Metode Fuzzy Time Series Model Chen-Hsu dan Model Lee dalam Memprediksi Kurs Rupiah terhadap Dolar Amerika*. <https://journals.sangkuriangpublisher.com/datamath>
- Silverberg, G., & Verspagen, B. (1999). *Long Memory in Time Series of Economic Growth and Convergence*. 99.8.
- Susilawati, R., & Sunendiari, S. (2022). Peramalan Jumlah Penumpang Kereta Api Menggunakan Metode Arima dan Grey System Theory. *Jurnal Riset Statistika*, 1–13. <https://doi.org/10.29313/jrs.vi.603>