

BAB I PENDAHULUAN

1.1 Latar Belakang

Dalam kehidupan sehari-hari, uang berfungsi sebagai alat tukar dan simbol nilai ekonomi yang diterima secara luas. Setiap negara memiliki mata uang sendiri yang menjadi tulang punggung aktivitas ekonomi domestik. Namun, dalam era globalisasi, nilai tukar mata uang menjadi pusat interaksi ekonomi antarnegara, memengaruhi daya beli domestik dan daya saing dalam perdagangan internasional, serta mencerminkan kekuatan ekonomi suatu negara (Meilania dkk., 2024). Keterkaitan ekonomi global telah meningkatkan interdependensi antara mata uang dan pasar keuangan di seluruh dunia. Faktor-faktor seperti pertumbuhan ekonomi, inflasi, suku bunga, dan ketidakpastian politik di satu negara dapat mempengaruhi nilai tukar mata uang di negara lain (Mukti dkk., 2024). Dalam perdagangan internasional, nilai tukar memainkan peran penting dalam kebijakan ekonomi. Nilai tukar yang kuat dapat memengaruhi daya beli negara terhadap impor barang-barang konsumsi, sementara nilai tukar yang lemah dapat memberikan keunggulan kompetitif bagi ekspor produk-produk domestik. Nilai tukar Rupiah terhadap Euro, khususnya, semakin relevan mengingat hubungan dagang yang erat antara Indonesia dan negara-negara Uni Eropa (Meilania dkk., 2024).

Eropa adalah salah satu mitra ekonomi utama Indonesia, sehingga fluktuasi nilai tukar Euro memengaruhi nilai tukar Rupiah. Fluktuasi ini penting diketahui oleh pemerintah, perusahaan yang terlibat dalam impor-ekspor, investor, dan pihak terkait lainnya agar dapat mengambil keputusan yang tepat. Untuk mengantisipasi perubahan ini, peramalan menjadi alat penting. Dengan memanfaatkan data masa lalu, peramalan membantu memprediksi nilai-nilai variabel di masa depan berdasarkan data runtun waktu yang dianalisis secara ilmiah (Ikhsanto dkk., 2018).

Data runtun waktu adalah serangkaian observasi suatu variabel berdasarkan interval waktu tetap (Wei, 2006). Analisis runtun waktu digunakan untuk memodelkan dan meramalkan keadaan di masa depan, dengan metode seperti *Autoregressive* (AR), *Moving Average* (MA), dan *Autoregressive Moving Average* (ARIMA) yang efektif untuk data dengan ketergantungan jangka pendek (*short memory*). Namun, dalam banyak bidang seperti ekonomi dan keuangan, sering ditemukan proses *long memory* (Akbar & Kharisudin, 2018).

Long memory adalah proses stasioner saat data menunjukkan korelasi jangka panjang yang signifikan. Hal ini dapat dilihat melalui nilai autokorelasinya yang turun lambat dalam waktu yang lama sehingga membentuk pola data yang hiperbolik. *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) adalah model yang mampu menjelaskan data dengan sifat *long memory*, berbeda dengan ARIMA yang hanya menangani *short memory*. ARFIMA memungkinkan pembedaan nilai pecahan, membuatnya mampu memodelkan baik *short memory* maupun *long memory*. Penentuan estimasi parameter pembeda pada model ARFIMA salah satunya dapat menggunakan metode *Geweke Porter Hudak* (GPH). Kelebihan dari metode ini adalah sifatnya yang fleksibel dalam menentukan parameter pembeda d meskipun nilai parameter p dan q belum diketahui (Hasan dkk., 2023).

Ketidakpastian pada data keuangan biasanya mengakibatkan terjadinya volatilitas. Volatilitas menggambarkan fluktuasi dalam data, yang dapat menyebabkan residual bersifat heteroskedastisitas. Teknik pemodelan yang sesuai untuk menangani data yang terindikasi adanya heteroskedastisitas pertama kali diperkenalkan oleh Engle (1982) dalam memodelkan inflasi yang terjadi di Inggris. Model yang digunakan dalam penelitian tersebut dikenal sebagai *Autoregressive Conditional Heteroscedasticity* (ARCH). Bollerslev (1986) mengembangkan model ini menjadi *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH), yang mempertimbangkan nilai residual dan ragam residual periode sebelumnya untuk menangani volatilitas data.

Beberapa penelitian telah dilakukan terkait ARFIMA dan *long memory*. Cahyandari dan Erviana (2015) memodelkan kurs jual mata uang kertas Singapore Dollar (SGD) terhadap Rupiah menggunakan ARFIMA menghasilkan model terbaik ARFIMA dengan MSE sebesar 2173,33, Paridi (2018) membandingkan metode ARIMA dan ARFIMA dalam peramalan jumlah kasus demam berdarah, dan hasil peramalan menggunakan model ARFIMA menghasilkan nilai MAPE yang lebih kecil dibandingkan ARIMA. Penelitian Setyowibowo dkk (2022) menunjukkan bahwa ARIMA-GARCH tidak hanya menangani heteroskedastisitas tetapi juga memberikan akurasi tinggi dengan MAPE sebesar 0,001168113%.

Model ARFIMA memiliki keunggulan dalam menangkap ketergantungan jangka panjang (*long memory*) dalam data. Sementara itu, model GARCH mampu menangani heteroskedastisitas pada residual. Kedua keunggulan ini menjadikan kombinasi ARFIMA-GARCH relevan untuk analisis data keuangan, termasuk nilai nilai tukar Rupiah terhadap Euro. Peramalan ini memiliki peran penting baik bagi individu maupun berbagai sektor dalam perekonomian untuk menghasilkan keputusan keuangan dalam jangka pendek maupun jangka panjang yang tepat, maka berdasarkan latar belakang yang dijabarkan, maka skripsi ini mengambil judul "*Penerapan Model Autoregressive Fractionally Integrated Moving Average - Generalized Autoregressive Conditional Heteroscedasticity dalam Peramalan Nilai Tukar Rupiah terhadap Euro*".

1.2 Tujuan dan Manfaat

Tujuan dilakukannya penelitian ini adalah:

1. Memperoleh model ARFIMA-GARCH terbaik untuk data nilai tukar Rupiah terhadap Euro.
2. Memperoleh peramalan data nilai tukar Rupiah terhadap Euro menggunakan model ARFIMA-GARCH.

Manfaat yang ingin dicapai penelitian ini antara lain:

1. Menambah wawasan keilmuan mengenai model ARFIMA-GARCH.
2. Memberikan informasi tentang hasil peramalan menggunakan model ARFIMA-GARCH pada nilai tukar Rupiah terhadap Euro.

1.3 Batasan Masalah

Batasan permasalahan dalam penelitian ini yaitu:

1. Identifikasi *long memory* pada data menggunakan plot ACF dan statistik Hurst (H).
2. Metode estimasi parameter *differencing* (d) yang digunakan adalah Geweke and Porter-Hudak (GPH).
3. Akurasi hasil peramalan dihitung menggunakan *Mean Absolute Percentage Error* (MAPE).

1.4 Teori

1.4.1 Analisis Runtun Waktu

Data runtun waktu merupakan serangkaian observasi terhadap suatu variabel yang diambil secara beruntun berdasarkan interval waktu yang tetap (Wei, 2006). Analisis runtun waktu merupakan salah satu prosedur statistika yang diterapkan untuk memodelkan dan meramalkan struktur probabilitas keadaan yang akan datang dalam rangka pengambilan keputusan. Dasar runtun waktu adalah pengamatan sekarang dipengaruhi oleh satu atau beberapa pengamatan sebelumnya. Dengan kata lain, model deret waktu dibuat untuk menganalisis pola dan korelasi antar pengamatan dalam suatu rentang waktu. Tujuan analisis runtun waktu antara lain memahami dan menjelaskan mekanisme tertentu, meramalkan suatu nilai di masa depan, dan mengoptimalkan sistem kendali (Suseno, 2017).

1.4.2 Proses Linear Stasioneritas

Stasioneritas dibedakan menjadi dua yaitu stasioner dalam rata-rata (*mean*) dan stasioner dalam variansi (ragam) (Wei, 2006). Stasioner dalam rata-rata adalah fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak bergantung pada waktu dan ragam dari fluktuasi tersebut. Dari bentuk plot data seringkali dapat diketahui bahwa data tersebut stasioner atau tidak stasioner. Apabila dilihat dari plot ACF (*Autocorrelation Function*), maka nilai-nilai autokorelasi dari stasioner akan turun menuju nol sesudah *time lag* (selisih waktu) kelima atau keenam. Sebuah data runtun waktu dikatakan stasioner dalam ragam apabila struktur dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah. Secara visual, hal tersebut dapat dilihat dengan menggunakan plot runtun waktu, yaitu dengan melihat fluktuasi data dari waktu ke waktu.

Sebelum melakukan pemodelan pada data deret waktu, stasioneritas data dapat diperiksa dengan mengamati ada atau tidaknya akar unit (*unit root*) dalam suatu data runtun waktu. Uji yang biasa digunakan adalah uji *Augmented Dickey-Fuller* (ADF). Hipotesis yang digunakan dalam uji ADF adalah (Rosadi, 2012):

$H_0: \delta = 0$ (terdapat akar unit, data tidak stasioner)

$H_1: \delta < 0$ (tidak terdapat akar unit, data stasioner)

Statistik uji ADF adalah sebagai berikut:

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

dengan, $\hat{\delta}$ adalah estimator *least square* dan $SE(\hat{\delta})$ merupakan *standard error* dari nilai estimasi δ (koefisien *standard error* dari model). Kriteria pengujian berdasarkan uji ADF adalah tolak H_0 jika $t_{hitung} > t_{tabel}$ atau $p\text{ value} < \alpha$.

Pemodelan data runtun waktu sering ditemukan kondisi rata-rata yang tidak stasioner, sehingga diperlukan suatu cara untuk menstasionerkan data yaitu dengan cara perbedaan (*differencing*). *Differencing* dilakukan agar dapat mengatasi korelasi antara Z_t dengan Z_{t-k} , dengan k yang cukup besar. Selain itu, apabila data runtun waktu tidak stasioner dalam ragam, maka dilakukan transformasi data. Metode transformasi yang umum digunakan adalah transformasi *Box-Cox*. Secara umum persamaan transformasi *Box-Cox* sebagai berikut (Wei, 2006):

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

dengan λ adalah parameter transformasi. Nilai λ yang dipilih adalah nilai yang meminimumkan jumlah kuadrat residual sehingga memiliki ragam yang minimum (Wei, 2006).

1.4.3 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial

1.4.3.1 Fungsi Autokorelasi

Autokorelasi merupakan korelasi atau hubungan antar data pengamatan suatu data runtun waktu. Untuk proses (Z_t) yang stasioner, $E(Z_t) = \mu$, $var(Z_t) = \sigma^2$ adalah konstan dan $Cov(Z_t, Z_{t+k})$ adalah fungsi dari selisih waktu $|t - (t + k)|$. Kovarians antara Z_t dan Z_{t+k} adalah:

$$\gamma_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (3)$$

Menurut (Wei, 2006), koefisien autokorelasi untuk lag k dari data runtun waktu dinyatakan sebagai berikut.

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} = \frac{E(Z_t - \mu)(Z_{t+k} - \mu)}{\sqrt{E(Z_t - \mu)^2}\sqrt{E(Z_{t+k} - \mu)^2}} = \frac{\gamma_k}{\gamma_0} \quad (4)$$

untuk suatu proses yang stasioner, fungsi autokovarian γ_k dan fungsi autokorelasi ρ_k memenuhi sifat-sifat berikut:

1. $\gamma_0 = Var(Z_t), \rho_0 = 1$,
2. $|\gamma_k| \leq \gamma_0, |\rho_k| \leq 1$,
3. $\gamma_k = \gamma_{-k}, \rho_k = \rho_{-k}$, untuk semua nilai k .

Sampel ACF didefinisikan dengan persamaan (Wei, 2006):

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (5)$$

Untuk $k = 0, 1, 2, \dots, n$ dengan $\bar{Z} = \frac{1}{n} \sum_{t=1}^n Z_t$,

dengan,

Z_t : nilai aktual pada waktu ke- t

k : lag

μ : rata-rata

γ_k : kovarians pada lag ke- k

ρ_k : autokorelasi pada lag ke- k

t : waktu pengamatan, $t = 1, 2, 3, \dots$

1.4.3.2 Fungsi Autokorelasi Parsial

Fungsi autokorelasi parsial atau *partial autocorrelation function* (PACF) digunakan untuk mengukur tingkat keeratan hubungan antara Z_t dan Z_{t+k} setelah dependensi linear dalam variabel $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ dihilangkan (Wei, 2006). Fungsi autokorelasi parsial (PACF) dapat didefinisikan sebagai berikut dapat didefinisikan sebagai berikut.

$$\phi_{kk} = \text{Corr}(Z_t, Z_{t+k} | Z_{t+k}, \dots, Z_{t+k-1}) \quad (6)$$

Sampel PACF didefinisikan dengan persamaan

$$\hat{\phi}_{kk} = \frac{\hat{\rho}_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \hat{\rho}_j} \quad (7)$$


dengan $\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j}$, $j = 1, 2, \dots, k-1$.

1.4.4 Proses Long Memory

Proses ARIMA sering dinyatakan sebagai proses jangka pendek (*short memory*) karena autokorelasi antara Z_t dan Z_{t+k} turun secara cepat untuk $k \rightarrow \infty$, dalam kasus-kasus tertentu autokorelasi turun lambat secara hiperbolik untuk lag yang semakin besar. Hal ini menunjukkan adanya hubungan antara pengamatan yang jauh terpisah atau memiliki ketergantungan jangka panjang. Suatu runtun waktu stasioner Z_t , $t = 1, 2, \dots, N$ tergolong ke dalam *long memory* ketika mempunyai fungsi korelasi $\rho(k)$ berlaku $k \rightarrow \infty$ adalah sebagai berikut.

$$\lim_{k \rightarrow \infty} \frac{\rho(k)}{C_p(k)^{2d-1}} = 1 \quad (8)$$

Adapun C_p adalah konstanta dan $d \in (0, 0.5)$ menunjukkan parameter *long memory*. Korelasi dari suatu proses *long memory* akan cenderung turun perlahan secara hiperbolik. Proses dikatakan *short memory* jika $d \in (-0.5, 0)$ (Beran, 2017).



Gambar 1. Perbandingan Plot ACF (a) Long Memory dan (b) Short Memory

Gambar 1 menunjukkan perbandingan plot *Autocorrelation Function* (ACF) antara proses *long memory* dan *short memory*. Proses long memory dihasilkan menggunakan model ARFIMA dengan parameter *fractional differencing* yang

menunjukkan peluruhan perlahan pada nilai ACF, menandakan adanya hubungan jangka panjang antar nilai dalam data. Sebaliknya, proses short memory dihasilkan menggunakan model ARIMA, yang menunjukkan peluruhan eksponensial pada nilai ACF, menandakan hubungan yang lebih terbatas dalam data.

Selain melihat dari plot ACF, adanya *long memory* pada data runtun waktu bisa diketahui melalui nilai Hurst (H) yang diperoleh dengan menggunakan statistik (Hurst, 1951). Apabila nilai $H = 0,5$, maka data tersebut memiliki sifat *short memory*. Apabila nilai H berada pada interval $0 < H < 0,5$, maka data tersebut memiliki sifat *intermediate memory*. Apabila nilai H berada pada interval $0,5 < H < 1$, maka data memiliki sifat *long memory*. Identifikasi *long memory* dengan menentukan nilai *Hurst* (H) diperoleh melalui perhitungan dengan metode *Rescaled Range Statistics* (R/S) dengan langkah-langkah sebagai berikut (Safitri dkk., 2019).

1. Menghitung rata-rata ($\bar{Z}$).

$$\bar{Z} = \frac{1}{T} \sum_{t=1}^T Z_t, \quad t = 1, 2, \dots, T \quad (9)$$

2. Menghitung *adjusted mean*.

$$Z_t^{adj} = Z_t - \bar{Z}, \quad t = 1, 2, \dots, T \quad (10)$$

3. Menghitung deviasi kumulatif.

$$Z_t^* = \sum_{t=1}^T Z_t^{adj}, \quad t = 1, 2, \dots, T \quad (11)$$

4. Menghitung rentang deviasi kumulatif.

$$R_t = \max(Z_1^*, Z_2^*, \dots, Z_t^*) - \min(Z_1^*, Z_2^*, \dots, Z_t^*), \quad t = 1, 2, \dots, T \quad (12)$$

5. Menghitung standar deviasi.

$$s_t = \sqrt{\frac{1}{T} \sum_{t=1}^T (Z_t - \bar{Z})^2}, \quad t = 1, 2, \dots, T \quad (13)$$

6. Menghitung *Rescaled Range* (R/S).

$$\left(\frac{R}{S}\right)_t = \frac{R_t}{s_t}, \quad t = 1, 2, \dots, T \quad (14)$$

7. Menentukan nilai *Hurst* (H) melalui statistic R/S dari data runtun waktu.

$$\left(\frac{R}{S}\right)_t = c \cdot t^H, \quad t = 1, 2, \dots, T \quad (15)$$

$$\log\left(\frac{R}{S}\right)_t = \log c + H \log t \quad (16)$$

dengan c suatu konstanta dan H nilai *Hurst*.

8. Selanjutnya nilai *Hurst* (H) dapat diperoleh dengan persamaan.

$$H = \frac{\sum_{j=1}^T (X_j - \bar{X})(Y_j - \bar{Y})}{\sum_{j=1}^T (X_j - \bar{X})^2} \quad (17)$$

dengan $X_j = \log t$ dan $Y_j = \log(R/S)_t$.

1.4.5 Model Runtun Waktu

1.4.5.1 Model *Autoregressive*

Proses representasi model *autoregressive* (AR) dengan $\pi_1 = \phi_1, \pi_2 = \phi_2, \dots, \pi_p = \phi_p$, dan $\pi_k = 0$ untuk $k > p$ maka bentuk fungsi persamaan AR pada orde p , yang dinotasikan $AR(p)$ adalah sebagai berikut:

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t \quad (18)$$

atau

$$\phi_p(B)Z_t = a_t \quad (19)$$

dengan, $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$

Z_t : nilai variabel pada waktu ke- t

B : operator *backshift*

$\phi_p(B)$: polinomial *autoregressive* ke- p

ϕ_p : koefisien atau parameter dari model *autoregressive* ke- p

a_t : variabel residual pada waktu ke- t

p : orde AR

1.4.5.2 Model *Moving Average*

Menurut (Wei, 2006), secara umum bentuk model MA dengan order q yang dinotasikan $MA(q)$ mempunyai persamaan sebagai berikut:

$$Z_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (20)$$

atau

$$Z_t = \theta_q(B)a_t \quad (21)$$

Z_t : nilai variabel pada waktu ke- t

B : operator *backshift*

$\theta_q(B)$: polinomial *moving average* ke- q

$a_{t-1}, a_{t-2}, \dots, a_{t-q}$: nilai variabel residual sebelumnya (*lag*)

θ_q : koefisien model MA yang menunjukkan bobot

a_t : variabel residual pada waktu ke- t

q : orde MA

Perbedaan model AR dengan model MA terletak pada jenis variabel independen. Bila variabel pada model MA yang menjadi variabel independen adalah nilai residual pada periode sebelumnya, sedangkan variabel pada model AR adalah nilai sebelumnya dari variabel independen.

1.4.5.3 Model *Autoregressive Moving Average*

Model *Autoregressive Moving Average* (ARMA) merupakan model gabungan antara AR dan MA, bentuk umum dari model $ARMA(p, q)$ adalah sebagai berikut.

$$\phi_p(B)Z_t = \theta_q(B)a_t \quad (22)$$

dengan, $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ dan $\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$

Z_t : nilai variabel pada waktu ke- t

B : operator *backshift*

$\phi_p(B)$: polinomial *autoregressive* ke- p

$\theta_q(B)$: polinomial *moving average* ke- q
 a_t : variabel residual pada waktu ke- t

1.4.5.4 Model Autoregressive Integrated Moving Average

Jika data deret waktu tidak stasioner, model Box-Jenkins ini disebut model *Autoregressive Integrated Moving Average* (ARIMA). Kestasioneran deret data pada level merupakan syarat utama dari model AR, MA, dan ARMA apabila deret data tidak stasioner pada rata-rata maka proses transformasi data dapat dilakukan. Bentuk transformasi data yang dapat dilakukan adalah dengan melakukan proses diferensiasi. Transformasi data dapat dilakukan melalui transformasi logaritma natural ($\ln$) dan proses diferensiasi. Secara umum model ARIMA (*Autoregressive Integrated Moving Average*) p, d, q dirumuskan dengan notasi sebagai berikut.

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t \quad (23)$$

dengan operator stasioner AR $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ dan operator invertibel MA $\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$. Parameter θ_0 memainkan peran yang sangat berbeda untuk $d = 0$ dan $d > 0$. Ketika $d = 0$, proses asli stasioner, dan θ_0 terkait dengan proses $\theta_0 = \mu(1 - \phi_1 - \dots - \phi_p)$.

1.4.5.5 Model Autoregressive Fractionally Integrated Moving Average

Model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) pertama kali dikembangkan oleh (Granger & Joyeux, 1980) yang merupakan pengembangan dari model *Autoregressive Integrated Moving Average* (ARIMA). (Hosking, 1981) memperkenalkan model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) untuk memodelkan data *long memory*. Proses ARFIMA (p, d, q), dengan p dan q adalah bilangan bulat non negatif dan $0 < d < 0,5$, merupakan runtun waktu stasioner dengan fungsi autokorelasi saat lagnya turun secara lambat (Brockwell & Davis, 2003). Model ARFIMA dapat mengatasi kelemahan model ARIMA, yaitu ARIMA hanya dapat menjelaskan data jangka pendek dengan *differencing* (d) bilangan bulat. Model ARFIMA merupakan model yang mampu menjelaskan data runtun waktu baik berupa data jangka pendek maupun jangka panjang dengan *differencing* (d) bernilai pecahan. Bentuk umum dari model ARFIMA (p, d, q) sebagai berikut (Wei, 2006):

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t \quad (24)$$

dengan,

d : parameter pembeda (bilangan pecahan)

$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ adalah polinomial *autoregressive* ke- p

$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ adalah polinomial *moving average* ke- q

$a_t \sim IIDN(0, \sigma^2)$

$(1-B)^d = \nabla^d = \sum_{k=1}^{\infty} \binom{d}{k} (-1)^k B^k$ operator pembeda pecahan.

Untuk suatu nilai d bernilai pecahan, operator fraksional diferensi $(1-B)^d$ didefinisikan sebagai berikut.

$$(1 - B)^d = 1 + \sum_{k=1}^{\infty} \frac{\Gamma(-d + k)}{\Gamma(-d)k!} B^k \quad (25)$$

Pada Persamaan (25) untuk berbagai nilai k , ekuivalen dengan:

$$\begin{aligned} (1 - B)^d &= 1 + \sum_{k=1}^{\infty} \frac{\Gamma(-d + k)}{\Gamma(-d)k!} B^k \\ &= 1 + \frac{\Gamma(-d + 1)}{\Gamma(-d)1!} B^1 + \frac{\Gamma(-d + 2)}{\Gamma(-d)2!} B^2 + \frac{\Gamma(-d + 3)}{\Gamma(-d)3!} B^3 + \dots \\ &= 1 + \frac{\Gamma(-d)}{\Gamma(-d - 1)1!} B^1 + \frac{\Gamma(-d + 1)}{\Gamma(-d - 1)2!} B^2 + \frac{\Gamma(-d + 1)}{\Gamma(-d - 1)3!} B^3 + \dots \\ &= 1 - dB - \frac{d(1 - d)B^2}{2} - \frac{d(1 - d)(2 - d)B^3}{6} + \dots \end{aligned} \quad (26)$$

Spectral density adalah sebuah fungsi real positif yang variabel frekuensinya dihubungkan dengan fungsi deterministik dari waktu. Dalam (Palma, 2007) *spectral density* dari Persamaan (26) adalah sebagai berikut.

$$\begin{aligned} f(\lambda_j) &= f_0(\lambda_j) \left[2 \sin \frac{\lambda_1}{2} \right]^{-2d} \\ &= \frac{\sigma^2}{2\pi} \left[2 \sin \frac{\lambda_1}{2} \right]^{-2d} \frac{|\theta(e^{-i\lambda})|^2}{|\phi(e^{-i\lambda})|^2} \end{aligned} \quad (27)$$

dengan $\frac{\sigma^2 |\theta(e^{-i\lambda})|^2}{2\pi |\phi(e^{-i\lambda})|^2}$ adalah *spectral density* dari proses ARMA(p, q) dan λ adalah frekuensi dari periodogram.

Fungsi autokovarian dari proses ARFIMA($0, d, 0$) adalah:

$$\gamma_0(k) = \sigma^2 \frac{\Gamma(1 - 2d)}{\Gamma(1 - d)\Gamma(d)} \frac{\Gamma(k + d)}{\Gamma(1 + k - d)} \quad (28)$$

dengan $\Gamma(x)$ adalah fungsi gamma, dan ACF dari proses ARFIMA($0, d, 0$) adalah

$$\rho_0(k) = \frac{\Gamma(1 - d)}{\Gamma(d)} \frac{\Gamma(k + d)}{\Gamma(1 + k - d)} \quad (29)$$

PACF dari proses ARFIMA($0, d, 0$) adalah sebagai berikut.

$$\phi_{nn} = \frac{d}{(n - d)} \quad (30)$$

dengan $\phi_{nn} \approx \frac{d}{n}$ untuk nilai n yang besar.

Menurut Hosking (1981) karakteristik utama dari sebuah model ARFIMA(p, d, q) adalah sebagai berikut:

1. Jika $|d| \geq 0,5$, maka proses panjang tidak stasioner
2. Jika $0 < d < 0,5$, proses berkorelasi panjang stasioner dengan adanya ketergantungan positif antar pengamatan yang terpisah jauh yang ditunjukkan dengan autokorelasi positif dan turun lambat dan mempunyai representasi *moving average* orde tak hingga.
3. Jika $-0,5 < d < 0$, maka proses berkorelasi panjang stasioner dengan memiliki ketergantungan negatif yang dengan autokorelasi negatif dan turun lambat serta mempunyai representasi autoregressive orde tak hingga.

4. Jika $d = 0$, maka proses menunjukkan fungsi autokorelasi turun secara eksponensial dengan proses ARMA.

Menurut Sowell (1999), keuntungan yang didapat jika menggunakan model ARFIMA(p, d, q) sebagai berikut:

1. Mampu memodelkan perubahan yang tinggi dalam jangka panjang (*long term presistence*).
2. Mampu menjelaskan struktur korelasi jangka panjang dan jangka pendek sekaligus.
3. Mampu memberikan model dengan parameter yang lebih sederhana (*parsimony*) baik untuk data dengan memori jangka panjang maupun jangka pendek.

1.4.6 Pemodelan Runtun Waktu dengan Metode Box-Jenkins

Tahapan pemodelan runtun waktu dengan menggunakan metode *Box-Jenkins* dilakukan melalui tahap identifikasi model, estimasi parameter model, pengujian parameter model, uji diagnostik model, dan pemilihan model terbaik. Setelah didapat model ARFIMA terbaik, dilakukan evaluasi model melalui analisis diagnostik residual, yaitu kehomogenan ragam residual.

1.4.6.1 Identifikasi Model

Langkah pertama dalam pembentukan model adalah membuat plot data runtun waktu. Pembuatan plot data runtun waktu bertujuan untuk menyelidiki stasioneritas dari data runtun waktu. Data runtun waktu dapat dikatakan stasioner apabila data tersebut stasioner terhadap ragam dan rata-rata.

Data yang belum stasioner dalam ragam maka harus dilakukan transformasi Box-Cox. Apabila data belum stasioner terhadap rata-rata maka dapat dilakukan pembedaan atau *differencing* hingga data stasioner dalam rata-rata. Setelah data runtun waktu sudah stasioner terhadap ragam dan rata-rata, selanjutnya dibuat grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data runtun waktu tersebut.

1.4.6.2 Estimasi Parameter Model

Identifikasi untuk model ARFIMA dilakukan dengan memperhatikan plot data runtun waktu untuk melihat pola data. Model ARFIMA(p, d, q), p merupakan orde untuk proses *autoregressive*, d merupakan orde *differencing*, dan q merupakan orde untuk proses *moving average*. Dalam penetapan p dan q dapat diperoleh dengan mengamati pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).

Salah satu metode pendugaan parameter yang digunakan untuk menduga parameter model AR(p) dan MA(q) adalah metode Exact Maximum Likelihood. Metode ini digunakan karena semua informasi yang tersedia dalam data dapat digunakan.

Fungsi autokorelasi dari proses AR stasioner yaitu:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + a_t \quad (31)$$

Karena $\tilde{Z}_t = Z_t - \mu$, Persamaan (31) dapat ditulis juga sebagai berikut.

$$Z_t - \mu = \phi_1 (Z_{t-1} - \mu) + \phi_2 (Z_{t-2} - \mu) + \dots + \phi_p (Z_{t-p} - \mu) + a_t \quad (32)$$

Sehingga jumlah kuadrat residual pada Persamaan (32) adalah:

$$S(\mu, \phi_1, \dots, \phi_p) = \sum_{t=p+1}^n a_t^2 = \sum_{t=p+1}^n [(Z_t - \mu) + \phi_1 (Z_{t-1} - \mu) + \dots + \phi_p (Z_{t-p} - \mu)]^2 \quad (33)$$

Proses *white noise* (a_t) merupakan deret dari peubah acak yang saling bebas dan mengikuti distribusi tertentu yang identik dengan $E(a_t) = 0$ serta $Var(a_t) = \sigma^2$, sehingga fungsi kepekatan peluang dari (a_t) adalah:

$$f(a_t | \mu, \phi, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{a_t^2}{2\sigma^2}} \quad (34)$$

dan fungsi kemungkinan dari $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_3)$ adalah:

$$L(\mu, \phi, \sigma^2 | a) = \prod_{t=1}^n f(a_t | \mu, \phi, \sigma^2) = (2\pi\sigma^2)^{-\frac{n}{2}} \exp \left[-\frac{1}{2\sigma^2} \sum_{t=1}^n a_t^2 \right] \quad (35)$$

Logaritma natural dari Persamaan (35) adalah:

$$\ln L(\mu, \phi, \sigma^2 | a) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{S(\mu, \phi_1, \dots, \phi_p)}{2\sigma^2} \quad (36)$$

Bila diperhatikan, parameter $\mu, \phi_1, \phi_2, \dots, \phi_p$ hanya dimuat pada jumlah kuadrat residual $S(\mu, \phi_1, \dots, \phi_p)$ sehingga fungsi $\ln L(\mu, \phi, \sigma^2 | a)$ akan maksimum jika $S(\mu, \phi_1, \dots, \phi_p)$ minimum. Sehingga penduga parameter $\mu, \phi_1, \phi_2, \dots, \phi_p$ dapat diperoleh dengan menyelesaikan Persamaan (37) dan (38).

$$\frac{\partial}{\partial \mu} S(\mu, \phi_1, \dots, \phi_p) = 0 \quad (37)$$

Penyelesaian dari Persamaan (37) akan diperoleh $\hat{\mu} = \bar{Z}$.

$$\frac{\partial}{\partial \phi_i} S(\mu, \phi_1, \dots, \phi_p) = 0 \quad (38)$$

Penyelesaian dari Persamaan (38) terhadap $\phi_1, \phi_2, \dots, \phi_p$ akan diperoleh penduga sistem persamaan *Yule Walker* sehingga untuk penduga AR(2) dengan metode *Exact Maximum Likelihood* (EML) diperoleh:

$$\hat{\phi}_1 = \frac{\hat{\rho}_1 - \hat{\rho}_1 \hat{\rho}_2}{1 - \hat{\rho}_1^2} \text{ dan } \hat{\phi}_2 = \frac{\hat{\rho}_2 - \hat{\rho}_1^2}{1 - \hat{\rho}_1^2}, \text{ dimana } \hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=h+1}^n (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}$$

Fungsi autokorelasi dari proses MA(q) adalah:

$$Z_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (39)$$

Model parameter MA(q) berbeda dengan model AR(p) karena model MA bersifat non-linear sehingga tidak dapat dilakukan secara analitik. Model MA(q) yang *invertible* dapat dituliskan menjadi:

$$Z_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (40)$$

$$Z_t = -\theta_1 a_{t-1} - \dots - \theta_q a_{t-q} + a_t \quad (41)$$

Penduga bagi θ bernilai riil dan *invertible* bila $|\rho_1| < 0,5$. Sehingga solusi dari penduga $\theta_1, \theta_2, \dots, \theta_q$ diperoleh dengan cara iteratif atau meminimumkan jumlah

kuadrat residual dari model MA yang dihasilkan melalui algoritma optimisasi numeris. Penduga parameter MA(q) yaitu:

$$\hat{\rho}_1 = \frac{\hat{\theta}}{1 + \hat{\theta}^2} \quad (42)$$

Metode estimasi parameter d yang akan digunakan pada ARFIMA(p, d, q) adalah metode Geweke *and* Porter-Hudak (GPH). Metode GPH pertama kali diusulkan oleh Geweke dan Porter-Hudak pada tahun 1983, dengan parameter differencing (d) dapat diestimasi secara konsisten dari regresi kuadrat terkecil yang diperoleh dari penaksiran persamaan logaritma *spectral density*. Kelebihan metode GPH dibandingkan dengan metode yang lain seperti metode Maksimum Likelihood dan Metode *Nonlinear Least Square* adalah fleksibilitas dalam estimasi parameternya. Estimasi parameter pembeda d pada metode GPH dapat dilakukan secara langsung tanpa mengetahui nilai p dan q terlebih dahulu. Menaksir parameter pembeda d dapat didekati dengan persamaan regresi linear sebagai berikut.

$$Y_j = \beta_0 + \beta_1 X_j + \alpha_j, \quad j = 1, 2, \dots, m \quad (43)$$

Sehingga parameter pembeda d dapat ditaksir melalui persamaan:

$$\beta_1 = \hat{d} = \frac{\sum_{j=1}^m (X_j - \bar{X})(Y_j - \bar{Y})}{\sum_{j=1}^m (X_j - \bar{X})^2} \quad (44)$$

dengan

$$\lambda_j = \frac{2\pi j}{T} \quad (45)$$

$$I(\lambda_j) = \frac{1}{2\pi} \{ \gamma_0 + 2 \sum_{t=1}^{T-1} \gamma_t \cos(t \cdot \lambda_j) \}, \lambda_j \in (-\pi, \pi) \quad (46)$$

$$X_j = \ln \left[2 \sin \left(\frac{\lambda_j}{2} \right) \right]^2 \quad (47)$$

$$Y_j = \ln I(\lambda_j) \quad (48)$$

dengan, T = jumlah pengamatan, $j = 1, 2, \dots, m$ dan $m = T^{0.5}$.

1.4.6.3 Uji Diagnostik Model

Setelah melakukan penaksiran nilai-nilai parameter dari model sementara, perlu dilakukan pengujian diagnostik model untuk membuktikan bahwa model tersebut telah memadai dan menentukan model terbaik untuk peramalan (Wei, 2006). Pada pengujian diagnostik ini dilakukan analisis nilai residual. Model dikatakan memadai jika nilai residual tidak berkorelasi, dan tidak terindikasi heteroskedastisitas. Selain itu nilai sisa juga harus memenuhi asumsi distribusi normal.

Pada penelitian ini, uji diagnostik dilakukan dua kali. Uji diagnostik pertama untuk model ARFIMA dan uji diagnostik kedua untuk model ARFIMA-GARCH. Berikut uji untuk uji diagnostik residual.

1. Uji Autokorelasi

Suatu residual yang bersifat *white noise* berarti residual dari model telah memenuhi asumsi identik serta independen. Suatu proses a_t disebut proses *white noise* jika terdiri dari variabel acak yang tidak berkorelasi antar variabel dan berdistribusi

normal dengan rata-rata konstan $E(a_t) = 0$, ragam konstan $Var(a_t) = \sigma^2$ dan $\gamma_k = Cov(a_t, a_{t+k}) = 0$ untuk $k \neq 0$ (Wei,2006).

Pengujian *white noise* dilakukan dengan menggunakan uji Ljung-Box, yang memiliki hipotesis sebagai berikut.

$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$ (Residual data bersifat *white noise*)

H_1 : minimal terdapat satu $\rho_k \neq 0$ (Residual data tidak bersifat *white noise*)

dengan, $k = 1, 2, \dots, K$

Statistik uji Ljung-Box adalah sebagai berikut (Wei,2006):

$$LB = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (49)$$

dengan

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

n : banyak data

Jika taraf signifikan yang digunakan adalah sebesar $\alpha(5\%)$ maka kriteria pengujian yang digunakan adalah tolak H_0 jika nilai $p - value < \alpha$.

2. Uji Normalitas

Uji normalitas digunakan untuk melihat kenormalan dari residual data. Pengujian normalitas residual salah satunya adalah dengan menggunakan uji *Kolmogorov-Smirnov*. Hipotesis dari uji ini adalah sebagai berikut.

$H_0: a_t \sim N(0, \sigma_{a_t}^2)$ (Residual berdistribusi normal)

$H_0: a_t \neq N(0, \sigma_{a_t}^2)$ (Residual tidak berdistribusi normal)

Statistik uji *Kolmogorov-Smirnov* adalah sebagai berikut.

$$D = \max |F_0(a_t) - S(a_t)| \quad (50)$$

dengan:

$F_0(a_t)$: fungsi peluang kumulatif dari distribusi normal

$S(a_t)$: fungsi peluang kumulatif data

Kriteria keputusan dari uji Kolmogorov-Smirnov adalah tolak H_0 jika $D \geq K_{(1-\alpha, n)}$ atau $p - value < \alpha$.

3. Uji ARCH-LM

Uji *ARCH-Lagrange Multiplier* (ARCH-LM) digunakan untuk menguji efek ARCH pada residual sebelum menggunakan model ARCH/ GARCH. Uji ARCH-LM digunakan dengan menguji signifikansi persamaan berikut.

$$\varepsilon_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_p \varepsilon_{t-p}^2 \quad (51)$$

Hipotesis yang digunakan dalam uji ARCH-LM adalah (Rosadi, 2012):

$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_p = 0$ (tidak terdapat efek ARCH/residual bersifat tidak heteroskedastisitas)

$H_1: \exists \alpha_i \neq 0, i = 1, 2, \dots, p$ (terdapat efek ARCH/residual bersifat heteroskedastisitas)

Statistik ujinya yaitu $TR^2 \sim X_p^2$

dengan T adalah banyaknya pengamatan dan R^2 adalah koefisien determinasi. Tolak H_0 jika $TR^2 > X_p^2$. Ini menunjukkan adanya efek ARCH dalam model (Junaidi, 2012).

1.4.6.4 Pemilihan Model Terbaik

Suatu model setelah diidentifikasi memungkinkan terbentuknya lebih dari satu model yang sesuai, untuk itu diperlukan pemilihan model yang terbaik. Kriteria pemilihan model yang akan digunakan untuk peramalan didasarkan pada nilai *Akaike's Information Criterion* (AIC) terkecil. Formulasi nilai AIC dapat dinyatakan sebagai berikut (Wei, 2006):

$$AIC(m) = n \ln \hat{\sigma}_\alpha^2 + 2m \quad (52)$$

dengan,

m : banyak parameter yang ditaksir

n : banyak pengamatan

$\hat{\sigma}_\alpha^2$: nilai ragam observasi

1.4.7 Volatilitas

Volatilitas adalah pengukuran statistik untuk fluktuasi harga selama periode tertentu. Ukuran tersebut menunjukkan penurunan dan peningkatan harga dalam periode yang pendek dan tidak mengukur tingkat harga, namun derajat ragam dari satu periode ke periode berikutnya. Volatilitas yang tinggi mencerminkan karakteristik penawaran dan permintaan yang tidak biasa. Biasanya volatilitas diestimasi dengan cara menghitung deviasi standar perubahan harga dalam waktu tertentu, yang menentukan seberapa cepat data berubah dengan keacakannya. Secara umum volatilitas mengukur rata-rata fluktuasi dari data runtun waktu. Namun hal ini dikembangkan lebih jauh dengan menekankan pada nilai ragam dari data, sehingga dapat dikatakan bahwa volatilitas sebagai nilai ragam dari data fluktuasi (Sunaryo, 2007).

Data runtun waktu, terutama data di sektor keuangan atau finansial, sangat tinggi volatilitasnya. Volatilitas yang tinggi ini ditunjukkan oleh suatu fase saat fluktuasinya relatif tinggi dan kemudian diikuti fluktuasi yang rendah dan kembali tinggi. Dengan kata lain data ini mempunyai rata-rata dan ragam yang tidak konstan (Widarjono, 2009).

1.4.8 Model Volatilitas Runtun Waktu

1.4.8.1 Model *Autoregressive Conditional Heteroscedasticity*

Model ARCH dikembangkan oleh Robert Engle (1982). Dalam model ARCH, ragam residual data runtun waktu tidak hanya dipengaruhi oleh variabel independen, tetapi juga dipengaruhi oleh nilai residual variabel yang diteliti. Model ini dapat dinyatakan sebagai berikut.

$$Y_t = \beta_0 + \beta_{1t}X_t + \dots + \beta_{rt}X_t + a_t \quad (53)$$

dan

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \alpha_r a_{t-r}^2 \quad (54)$$

dengan Y adalah variabel dependen, X variabel independen, a_t adalah residual, σ_t^2 adalah ragam residual, $\alpha_1 a_{t-1}^2$ disebut komponen ARCH (Vogelvang, 2005).

Ragam residual memiliki dua komponen, yaitu konstanta dan residual dari periode sebelumnya. Itulah sebabnya model ini disebut model bersyarat

(*conditional*), karena ragam residual periode sekarang (t) dipengaruhi oleh periode sebelum-sebelumnya ($t - 1$, $t - 2$, dan seterusnya). Persamaan (40) disebut dengan persamaan rata-rata bersyarat (*conditional mean*) dan Persamaan (41) disebut dengan persamaan ragam bersyarat (*conditional variance*) (Winarno, 2015).

1.4.8.2 Model *Generalized Autoregressive Conditional Heteroscedasticity*

Bollerslev (1986) mengembangkan metodologi ARCH dalam bentuk yang lebih umum yang dikenal sebagai *Generalized ARCH* (GARCH). Dalam model ini, ragam bersyarat tidak hanya dipengaruhi oleh residual yang lampau tetapi juga oleh *lag* ragam bersyarat itu sendiri.

Dengan demikian ragam bersyarat pada model GARCH terdiri atas dua komponen, yakni komponen lampau dari residual kuadrat (dinotasikan dengan derajat p dan komponen lampau dari ragam bersyarat (dinotasikan dengan derajat q), dalam bentuk matematis:

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i a_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (55)$$

Jika $q = 0$ maka diperoleh model ARCH Engle, sementara jika $r = s = 0$, dimiliki proses *white noise* dengan ragam ω . Hal ini menunjukkan bahwa meskipun proses s_t bersifat tidak berkorelasi namun proses ini tidak bersifat independen.

Dalam model GARCH(p, q), proses a_t dapat didefinisikan dengan menggunakan persamaan berikut.

$$a_t = \sigma_t v_t \quad (56)$$

dengan σ_t adalah akar dari σ_t^2 dan v_t adalah proses IID (*Independent and Indentically Distributed*), sering kali diasumsikan berdistribusi normal standar $N(0,1)$.

1.4.9 Akurasi Model Peramalan

Tingkat keakuratan model dilakukan dengan melakukan perhitungan galat untuk dapat melihat seberapa akurat data hasil pemodelan dari model yang telah diperoleh dengan data aktual. Pemodelan dengan tingkat galat terkecil adalah pemodelan yang terbaik. Salah satu metode untuk menghitung besar galat ini adalah *Mean Absolute Percentage Error* (MAPE).

Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur nilai dugaan model yang dinyatakan dalam bentuk persentase rata-rata absolut kesalahan. Formulasi nilai MAPE dinyatakan sebagai berikut (Montgomery dkk, 2015):

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{Z_t} \times 100\% \quad (57)$$

dengan,

Z_t : nilai aktual pada waktu ke- t

$\hat{Z}_t$: nilai prediksi pada waktu ke- t

n : banyak data yang diprediksi.

Kriteria nilai MAPE disajikan pada Tabel 1 (Chang dkk., 2006):

Tabel 1. Kriteria Nilai MAPE

Nilai MAPE	Kriteria
<10%	Kemampuan Peramalan Sangat Baik
10% - 20%	Kemampuan Peramalan Baik
20% - 50%	Kemampuan Peramalan Cukup Baik
>50%	Kemampuan Peramalan Buruk

1.4.10 Nilai Tukar

Nilai tukar atau kurs antara dua negara adalah tingkat harga yang disepakati oleh penduduk kedua negara untuk saling melakukan transaksi perdagangan (Mankiw, 2009). Jika kurs melemah disebut depresiasi atau penurunan nilai mata uang dalam negeri terhadap mata uang asing. Sebaliknya jika kurs menguat di sebut apresiasi atau kenaikan dalam nilai mata uang dalam negeri. Nilai tukar sangat berperan penting dalam kegiatan perdagangan dan jual beli antar negara. Apabila depresiasi mata uang suatu negara terhadap mata uang lainnya akan menyebabkan ekspor lebih murah dan impor lebih mahal, dan sebaliknya apabila apresiasi mata uang maka akan menyebabkan ekspor lebih mahal dan impor lebih murah (Rasyid, 2016).

Nilai tukar dipengaruhi oleh berbagai faktor ekonomi makro seperti suku bunga, inflasi, stabilitas politik, dan kebijakan moneter. Misalnya, kenaikan suku bunga dapat meningkatkan daya tarik mata uang dan permintaannya di pasar valuta asing, sementara inflasi tinggi atau ketidakstabilan politik dapat menyebabkan depresiasi nilai tukar (Susilowati & Rosento, 2020). Peristiwa non-ekonomi juga tidak bisa dilepaskan pengaruhnya terhadap pergerakan kurs mata uang. Terlebih, pergerakan kurs merupakan pergerakan yang cepat sekali berubah setiap hari. Peristiwa non-ekonomi juga tidak bisa dilepaskan pengaruhnya terhadap pergerakan kurs mata uang. Terlebih, pergerakan kurs merupakan pergerakan yang cepat sekali berubah setiap hari. Hubungan antara kedua variabel tersebut semakin menarik apabila variabel non-ekonominya merupakan suatu peristiwa yang berskala besar, dahsyat, dan berdampak nasional atau internasional seperti peristiwa politik dan kesehatan global. Peristiwa demikian tentunya bisa berdampak signifikan bagi suatu perekonomian termasuk pergerakan kurs (Hardianto, 2011).

BAB II METODE PENELITIAN

2.1 Sumber Data

Penelitian ini menggunakan data sekunder yaitu data nilai tukar Rupiah terhadap Euro yang diperoleh secara *online* dari <https://www.investing.com/>. Data tersedia dalam frekuensi harian, mingguan, namun dalam penelitian ini difokuskan pada data mingguan. Data mingguan yang digunakan dalam penelitian ini diambil dari tanggal 7 Januari 2018 hingga 30 Juni 2024, dengan jumlah data sebanyak 339 data.

2.2 Metode Analisis

Data yang sudah terkumpul dibagi menjadi dua yaitu data *training* untuk penentuan model dan data *testing* untuk validasi peramalan. Adapun langkah-langkah analisis data yang digunakan dalam penelitian yaitu sebagai berikut.

1. Memeriksa kestasioneran data dengan melihat plot data awal serta melakukan uji *Box-Cox* apabila data tidak stasioner terhadap ragam. Selanjutnya melakukan uji *Augmented Dickey-Fuller* (ADF) untuk melihat kestasioneran dalam rata-rata.

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

2. Identifikasi indikasi *long memory* pada data dengan melihat plot ACF. Jika pola plot ACF turun lambat atau hiperbolik, maka terdapat indikasi *long memory*. Indikasi *long memory* juga bisa diketahui dengan melihat nilai *Hurst* (H).

Kriteria uji statistik *Hurst*:

- $0 < H < 0,5$ menunjukkan sifat *short memory*
- $0,5 < H < 1$ menunjukkan sifat *long memory*

3. Menetapkan estimasi parameter d terlebih dahulu dengan menggunakan metode *Geweke and Porter-Hudak* (GPH).
4. Menetapkan beberapa model ARFIMA(p, d, q) berdasarkan plot ACF dan PACF data yang telah dilakukan *differencing* dengan nilai d yang telah diperoleh. Kemudian estimasi parameter ϕ dan θ pada model yang sudah ditetapkan menggunakan metode *Exact Maximum Likelihood*.
5. Melakukan pemilihan model yang signifikan. Suatu parameter model dikatakan signifikan apabila nilai statistik $p\text{-value} < \text{level of significant}$ ($\alpha = 0,05$).
6. Pemilihan model ARFIMA yang digunakan untuk peramalan berdasarkan nilai *Akaike's Information Criterion* (AIC) terkecil.
7. Melakukan uji efek ARCH terhadap residual dari model ARFIMA untuk mengetahui ada tidaknya gejala heteroskedastisitas dengan menggunakan uji ARCH-LM.
8. Mengidentifikasi dan menduga parameter model ARCH/GARCH.
9. Melakukan uji diagnostik model ARFIMA-ARCH/GARCH berupa pengujian asumsi ragam residual homogen dengan menggunakan uji ARCH-LM. Selain

itu, juga dilakukan pengujian autokorelasi dan normalitas residUal terhadap model ARCH/GARCH yang terbentuk.

10. Menentukan model ARFIMA-ARCH/GARCH terbaik berdasarkan nilai *Akaike's Information Criterion* (AIC) terkecil.
11. Melakukan evaluasi model. Jika GARCH merupakan model yang terbaik, maka evaluasi model dilakukan dengan analisis diagnostik residual seperti pada model ARFIMA.
12. Melakukan peramalan menggunakan model ARFIMA-GARCH terbaik guna mendapatkan nilai ramalan beberapa periode ke depan.
13. Model ARFIMA-GARCH yang telah ditentukan digunakan untuk evaluasi hasil peramalan. Kemudian dicari nilai galatnya menggunakan *Mean Absolute Percentage Error* (MAPE).