

BAB II

TINJAUAN PUSTAKA

2.1 Nilai Tukar

Nilai tukar (atau dikenal sebagai kurs) merupakan harga mata uang dari suatu negara terhadap mata uang negara lain. Perbandingan nilai merupakan sebutan lain dari kurs artinya, ketika terjadi pertukaran antara dua mata uang yang berbeda, maka akan menghasilkan perbandingan nilai atau harga dari kedua mata uang tersebut. Kurs mempunyai peran penting dalam hal bertransaksi. Hal itu karena kurs dapat membantu menerjemahkan harga-harga dengan mata uang yang berbeda dari berbagai negara. Menurut Kusuma (2019), kurs juga memiliki peran yang penting di pasar valuta asing (*foreign exchange market*).

Terjadi pertukaran mata uang dengan kurs yang disepakati oleh beberapa pihak yang terjadi di pasar valuta asing. Menurut Thionita (2018) dalam Kesumawati, A. (2020) kurs dapat mengalami dua macam perubahan, yaitu apresiasi dan depresiasi. Kenaikan nilai mata uang sendiri terhadap mata uang asing disebut apresiasi, hal tersebut terjadi karena di pasar valuta asing terdapat daya tarik menarik yang kuat antara permintaan dan penawaran. Ekspor menjadi lebih mahal dan impor menjadi lebih murah jika mata uang mengalami apresiasi terhadap mata uang lainnya. Sedangkan depresiasi adalah peristiwa menurunnya nilai mata uang sendiri terhadap mata uang asing. Ekspor menjadi lebih murah dan impor menjadi lebih mahal jika terjadi depresiasi mata uang dengan mata

uang lainnya. Menurut Thionita (2018) dalam Kesumawati, A. (2020) nilai kurs merupakan data deret waktu (*time series*) karena nilainya bisa berubah pada setiap harinya, perubahan tersebut bisa disebabkan oleh kondisi prekonomian dunia dan dalam negeri, juga oleh kondisi sosio-politik.

2.2 Data Runtun Waktu

Data runtun waktu adalah himpunan observasi terurut dalam waktu atau dalam dimensi lain yang menurut sejarah observasinya, runtun waktu dibedakan menjadi dua yaitu runtun waktu deterministik dan runtun waktu stokastik (Dwitanto, 2011). George E.P.Box dan Gwilym M.Jenkins (1976) merupakan tokoh pertama yang mengenalkan analisis runtun waktu, ia menjelaskan pemikiran *time series* adalah pengamatan sekarang bergantung pada pengamatan sebelumnya. Kustiara, dkk (2020) mengatakan ciri-ciri observasi data runtun waktu adalah interval antar indeks waktu t dapat dinyatakan dalam satuan waktu yang sama (identik).

Mutiara (2015) menjelaskan beberapa jenis data menurut waktu dibedakan menjadi 3, diantaranya sebagai berikut.

1. Data *Cross Section* adalah jenis data yang dikumpulkan untuk jumlah variabel pada suatu titik waktu tertentu. Model yang digunakan untuk memodelkan tipe ini adalah model regresi.
2. Data runtun waktu (*time series*) adalah jenis data yang dikumpulkan menurut urutan waktu dalam suatu rentang waktu tertentu. Model yang digunakan untuk memodelkan tipe ini adalah model-model time series.

3. Data Panel adalah jenis data yang dikumpulkan menurut urutan waktu dalam suatu rentang waktu tertentu pada sejumlah kategori. Model yang digunakan untuk memodelkan tipe ini adalah model data panel, model runtun waktu multivariate.

Sedangkan mengenai pola data menurut Hendikawati (2015) dapat dibedakan menjadi empat, diantaranya sebagai berikut.

1. Pola horizontal (H)

Pola ini terjadi apabila data berfluktuasi di sekitar nilai rata-rata yang konstan (data ini stasioner terhadap nilai rata-ratanya).

2. Pola data musiman (S)

Pola ini terjadi apabila nilai data dipengaruhi oleh faktor musiman (misalnya kuartal tahun tertentu, bulanan atau hari-hari pada minggu tertentu).

3. Pola siklis (C)

Pola ini terjadi apabila datanya dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti yang berhubungan dengan siklus bisnis.

4. Pola trend (T)

Pola ini terjadi apabila ada kenaikan atau penurunan sekuler jangka panjang dalam data.

2.3 Peramalan (*Forecasting*)

Peramalan terjadi karena adanya waktu senjang (*timelag*) antara kesadaran akan peristiwa atau suatu kebutuhan mendatang dengan peristiwa itu sendiri.

Peramalan diperlukan untuk menetapkan suatu peristiwa yang akan terjadi sehingga tindakan yang tepat dapat dilakukan. Menurut (Frechtling, 2001 dalam Gesafito 2016), peramalan pada dasarnya merupakan proses menyusun informasi tentang kejadian di masa lampau yang berurutan untuk menduga kejadian di masa yang akan datang. Dalam meramalkan peramalan sangat dibutuhkan data-data yang sesuai dan cara yang tepat sehingga dapat diperoleh peramalan yang akurat.

2.4 Volatilitas

Menurut Rosadi (2014) untuk menggambarkan fluktuasi dari suatu data dikenalkan konsep volatilitas. Volatilitas dapat didefinisikan sebagai varians bersyarat dari suatu data relatif terhadap waktu. Volatilitas dianggap sebagai suatu hal yang tak dapat diamati (*unobservable*) sehingga diperlukan perbandingan (de Vilder dan Visser, 2007 dalam Sari, 2019). Oleh karena itu, perhitungan volatilitas merupakan sebuah dugaan. Volatilitas biasanya dihitung dengan menggunakan ragam atau simpangan baku. Pengukuran volatilitas bertujuan untuk mengetahui fluktuasi harga suatu aset dan mengestimasi kerugian yang akan diderita. Nilai volatilitas yang tinggi menunjukkan bahwa terjadi fluktuasi pada suatu aset dengan range yang sangat lebar. Sedangkan volatilitas dikatakan rendah jika suatu aset tidak berfluktuasi atau jarang berubah dan cenderung konstan (Sartono, dkk., 2017 dalam Ramadhana, 2021).

2.5 Heterokedastisitas

Varians dari residuals tidak berubah dengan berubahnya satu atau lebih variabel bebas. Jika asumsi ini terpenuhi, maka residual bersifat homoskedastisitas. Jika varians residual tidak konstan maka residual bersifat heteroskedastisitas.

Heterokedastisitas dinyatakan dengan persamaan.

$$\text{var}((\varepsilon|y_1, y_2, \dots, y_3)) = \sigma_i^2$$

Dengan indeks i menunjukkan bahwa varians berubah dari observasi ke observasi.

Metode yang paling cepat dan mudah dilakukan dalam menguji adanya masalah heteroskedastik adalah dapat dilakukan dengan mendeteksi pola residual melalui sebuah grafik. Diketahui jika residual mempunyai varian yang sama (homoskedastik) maka tidak mempunyai pola yang pasti dari residual. Sebaliknya jika residual mempunyai sifat heteroskedastik, residual ini akan menunjukkan pola yang tertentu (Kustiara, 2019).

2.6 Stasioneritas Data

Salah satu karakteristik dari data runtun waktu adalah stasioner. Suatu proses analisis runtun waktu dikatakan stasioner, jika dalam proses tersebut terdapat rataan dan ragam yang konstan. Stasioner dapat dilihat dengan melihat plot data runtun waktu. Suatu data pengamatan dapat dinyatakan stasioner apabila data tersebut memiliki nilai rata-rata yang relatif konstan, tidak tergantung pada waktu dan varians dari fluktuasi tersebut (Makridakis, 1999 dalam Kustiara,

2019). Pada model stasioneritas, sifat-sifat statistik di masa yang akan datang dapat diramalkan berdasarkan data historis yang telah terjadi di masa lalu. Cara yang digunakan untuk mengetahui kestasioneran data yaitu dengan *Box-Cox Transformation* dan *Augmented Dickey Fuller (ADF)*. Menurut Chatfield (2004) proses stasioner mempunyai nilai *mean* dan varians yang konstan serta autokovarians yang bergantung pada selisih waktu. Nilai *mean*, varians, dan autokovarians secara sistematis ditunjukkan sebagai berikut.

$$\begin{aligned} \text{Var}(Y_t) &= E(Y_t - \mu)^2 = \sigma^2 \\ E(Y_t) &= \mu \\ \gamma_k = \text{Cov}(Y_t, Y_{t+k}) &= E(Y_t - \mu)(Y_{t+k} - \mu) \end{aligned}$$

2.6.1 Stasioner terhadap Varians

Box-Cox Transformation merupakan transformasi pangkat pada variabel tidak bebas, di mana suatu deret waktu yang tidak stasioner dalam hal varians harus diubah menjadi data stasioner. Pengujian yang dapat dilakukan untuk menjadikan data stasioner terhadap varians yaitu dengan cara di transformasi data. Pada uji ini digunakan apabila terjadi ketidakstasioneran pada data dalam hal varians.

Transformasi *box-cox* merupakan transformasi pangkat berparameter tunggal λ (lambda) terhadap variabel Y. Maka dapat dilakukan transformasi terhadap Y yang dipangkatkan dengan parameter λ . Secara umum, dapat dirumuskan sebagai berikut (Wei, 2006).

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda}$$

di mana λ adalah sebuah parameter transformasi *Box-Cox* (Shumway dan Stoffer, 2011). Berikut ini merupakan nilai λ dengan model transformasinya (Kutner, 2005 dalam Risma & Sahriman, 2020).

Tabel 2. 1 Transformasi *Box-Cox*

| Nilai λ | Transformasi Y_t |
|-----------------|--------------------|
| -1 | $1 / Y_t$ |
| -0.5 | $1 / \sqrt{Y_t}$ |
| 0 | $\ln Y_t$ |
| 0.5 | $\sqrt{Y_t}$ |
| 1 | Y_t |

2.6.2 Stasioner terhadap Rata-rata

Suatu data dapat dikatakan stasioner dalam rata-rata apabila fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan variansi dari fluktuasi tersebut (Wei, 2006). *Augmented Dickey-Fuller* (ADF) adalah uji yang paling sering digunakan untuk melihat kestasioneran data terhadap rata-rata. Alasan bahwa *ADF Test* sering digunakan karena telah mempertimbangkan kemungkinan adanya autokorelasi pada *error term* jika *series* yang digunakan non-stasioner. Uji ADF pertama kali diperkenalkan oleh David Dickey dan Wayne Fuller. Uji *Augmented Dickey Fuller* (ADF) merupakan pengujian stasioner terhadap mean dengan menentukan apakah data time series mengandung akar unit (*unit root*).

Hipotesis dalam pengujian ini adalah:

H_0 : data tidak stasioner

H_1 : data stasioner

Statistik uji:

$$t = \frac{\hat{\phi}}{se(\hat{\phi})}$$

Taraf signifikansi: $\alpha=5\%$

Pengambilan keputusan:

Jika nilai t-statistik > nilai $\alpha=5\%$ maka H_0 ditolak.

Apabila data tidak stasioner, maka perlu dilakukan proses *differencing* untuk menghasilkan data yang stasioner terhadap rata-rata. *Differencing* merupakan selisih nilai data pada suatu periode dengan nilai data pada periode sebelumnya. Jika *differencing* dirasa masih belum menghasilkan data yang stasioner, maka dapat dilakukan *differencing* ordo kedua, dan seterusnya hingga diperoleh data yang stasioner.

Persamaan untuk *differencing* data adalah sebagai berikut:

$$\Delta Y_t = Y_t - Y_{t-1}$$

Keterangan:

Y_t : variabel pengamatan t

Y_{t-1} : variabel pengamatan pada t - 1

t: waktu

2.7 Autokorelasi

Autokorelasi bertujuan untuk menentukan koefisien korelasi pada deret runtun waktu. Dalam analisis *time series*, terdapat dua konsep penting yang dikenal dengan fungsi autokorelasi atau *Autocorrelation Function* (ACF) dan fungsi autokorelasi parsial atau *Partial Autocorrelation Function* (PACF). Kedua jenis korelasi tersebut biasanya digunakan dalam spesifikasi model.

2.7.1 Fungsi Autokorelasi (ACF)

Fungsi Autokorelasi, ρ_k merupakan ukuran korelasi antara dua nilai Y_t dan Y_{t+k} dengan jarak k bagian atau disebut koefisien korelasi pada lag k . Untuk Y_t yang stasioner terdapat nilai rata-rata $E(Y_t) = \mu$ dan ragam $Var(Y_t) = E(Y_t - \mu)^2 = \sigma^2$ adalah konstan. ACF pada lag k dilambangkan dengan ρ_k yang didefinisikan sebagai berikut:

$$\rho_k = \frac{\gamma_k}{\gamma_0}$$

Dengan definisi γ_k sebagai fungsi autokovarians, γ_0 sebagai fungsi varians, dan ρ_k sebagai fungsi autokorelasi.

2.7.2 Fungsi Parsial Autokorelasi (PACF)

Plot Autokorelasi Parsial digunakan untuk mengukur tingkatan keeratan hubungan antara Y_t dan Y_{t+k} dengan mengabaikan ketidakbebasan $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ sehingga Y_t dianggap sebagai konstan.

$$\rho_k = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k}$$

Dengan definisi ϕ_{kk} sebagai fungsi autokorelasi parsial (*Partial Autocorrelation Function*) untuk $j= 1, 2, \dots, k$. Dalam penentuan pola PACF dibedakan menjadi dua yaitu menurun secara eksponensial menuju nol (*dies down*) dan signifikan pada semua lag (*cut off lag*). Untuk penentuan model dengan menggunakan pola ACF dan PACF dapat dilihat pada tabel model sebagai berikut Wei (1990).

Tabel 2. 2 Pola ACF dan PACF

| Model | ACF | PACF |
|-----------|------------------------------|------------------------------|
| AR(p) | <i>Dies down</i> | <i>Cut off</i> setelah lag p |
| MA(q) | <i>Cut off</i> setelah lag p | <i>Dies down</i> |
| ARMA(p,q) | <i>Dies down</i> | <i>Dies down</i> |

2.8 Model ARIMA

ARIMA yang juga sering disebut metode runtun waktu Box-Jenkins adalah teknik untuk mencari pola yang paling cocok dari sekelompok data (*curve fitting*), dengan demikian ARIMA memanfaatkan sepenuhnya data masa lalu dan sekarang untuk melakukan peramalan jangka pendek yang akurat. Peramalan jangka panjang dengan metode ARIMA memiliki ketepatan peramalan yang kurang baik, biasanya akan cenderung konstan.

Model ARIMA merupakan model gabungan antara *autoregressive* (AR) dan *moving average* (MA) di mana model ini mampu mewakili deret waktu yang stasioner dan non-stasioner. Tujuan model ARIMA adalah untuk menentukan hubungan statistik yang baik antar variabel yang diramal dengan nilai historis variabel tersebut sehingga peramalan dapat dilakukan dengan model tersebut.

Model pada metode ARIMA terdiri dari beberapa model yaitu *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA) dan *Autoregressive Integrated Moving Average* (ARIMA).

a. Model *Autoregressive* atau AR (p)

Metode *Autoregressive* adalah model yang menggambarkan bahwa variabel dependent di pengaruhi oleh variabel dependent itu sendiri. Bentuk umum autoregressive dengan ordo p atau ditulis dengan AR (p) atau model ARIMA (p,0,0) mempunyai persamaan sebagai berikut:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \dots + \phi_p Y_{t-p} + e_t$$

Keterangan:

Y_t : data pada periode t, t = 2, 1, ..., n

Y_{t-p} : data pada periode t-i, i = 2, 1, ..., p

ϕ_p : parameter *autoregressive* ke-i, i = 2, 1, ..., p

e_t : nilai kesalahan pada waktu ke-t

b. Model *Moving Average* atau MA (q)

Sebagai suatu alternative dari representasi *autoregressive* dengan X_t diasumsikan sebagai kombinasi linier. Model *Moving Average* mempunyai bentuk umum dengan ordo q atau biasa ditulis dengan MA (q) atau ARIMA (q,0,0) adalah sebagai berikut:

$$Y_t = \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} - \dots - \theta_q \alpha_{t-q}$$

Keterangan:

Y_t : data pada periode t, t = 2, 1, ..., n

α_t : nilai kesalahan pada waktu ke-t

θ_j : parameter *moving average* ke j, $j = 2, 1, \dots, q$

c. *Autoregressive Moving Average* atau ARMA(p,q)

Model ini merupakan gabungan antara AR(p) dengan MA(q), sehingga disebut sebagai ARMA(p,q). Bentuk umumnya dari persamaan ARMA(p,q) adalah sebagai berikut.

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \dots + \phi_p Y_{t-p} + \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} - \dots - \theta_q \alpha_{t-q}$$

Keterangan:

Y_t : data pada periode t

Y_{t-i} : data periode t-i

ϕ : parameter *autoregressive* ke-i

θ : parameter *moving average* ke-j

d. Model ARIMA(p,d,q)

Jika data *time series* nonstasioner maka perlu ditambahkan pada model ARMA yaitu orde *differencing* (d) dengan modelnya yaitu ARIMA(p,d,q). Model ARIMA(p,d,q) secara umum dapat ditulis sebagai berikut.

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta_q(B)\alpha_t$$

Dengan,

Y_t : data deret waktu

θ_0 : konstanta

$\phi_p(B) = 1 - \phi_p B - \dots - \phi_p B^p$: persamaan polynomial AR(p)

$\theta_q(B) = 1 - \theta_q B - \dots - \theta_q B^q$: persamaan polynomial MA(q)

$B = \text{backward shift operator}, BZ_t = Z_{t-1}$

α_t : residual deret waktu

2.9 Estimasi Parameter

Tahap selanjutnya untuk mencari model terbaik yaitu dengan mengestimasi parameter dalam model tersebut. Pada tahap ini akan diperoleh estimasi koefisien-koefisien dari model yang telah diperoleh pada identifikasi. Setelah diperoleh hasil estimasi parameter model, dilakukan uji signifikansi parameter. Uji ini digunakan untuk mengetahui parameter AR(p), *differencing*(d), dan MA(q) signifikan atau tidak. Jika parameter tersebut signifikan maka model layak digunakan.

Hipotesis:

H_0 : Parameter tidak signifikan dalam model

H_1 : Parameter signifikan dalam model

Statistik Uji:

$$t_{hit} = \frac{\hat{\beta}}{s.e.(\hat{\beta})}$$

Kriteria penolakan:

H_0 ditolak jika $|t_{hit}| > t_{(\frac{\alpha}{2}, n-n_p)}$, dengan n_p adalah jumlah parameter dalam model.

2.10 Kesesuaian Model

Kesesuaian model dilakukan terhadap residual dari model. Terdapat dua pengujian pada residual, yaitu uji *white noise* dan uji normalitas.

2.10.1 Asumsi *White Noise*

Deret waktu dikatakan *white noise* jika ada sebuah barisan dari variabel bebas yang tidak berkorelasi dengan rata-rata dan varians konstan. Pengujian *white noise* dapat dilihat melalui plot ACF dan PACF. Kriteria *error white noise* yaitu jika tidak ada lag yang melewati garis putus-putus merah atau selang kepercayaan. Uji *Q-Ljung-Box* digunakan untuk mengetahui apakah residual memenuhi asumsi *white noise*.

Hipotesis:

$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$ (parameter sama dengan nol (*residual* tidak berkorelasi))

$H_1: \rho_k \neq 0$ (parameter tidak sama dengan nol (*residual* berkorelasi))

Taraf signifikansi: $\alpha = 5\%$

Statistik Uji:

$$Q = n(n + 2) \sum_{k=1}^K \frac{r_k^2}{n - k}$$

dengan,

K: lag maksimum

n: jumlah pengamatan

r_k : Kriteria pengujian:

Jika $p\text{-value} < \alpha = 5\%$, maka H_0 ditolak sedangkan jika $p\text{-value} > \alpha = 5\%$ maka H_0 diterima.

2.10.2 Uji Distribusi Normal

Terdapat beberapa metode yang bisa digunakan untuk menguji berdistribusi normal atau tidak. Salah satu metode dalam pengujian distribusi normal dengan menggunakan Uji Jarque-Bera. Pengujian dilakukan pada residual model. Statistik uji *Jarque-Bera* adalah sebagai berikut.

$$JB = \frac{n}{6} \left(S^2 + \frac{(K - 3)^2}{4} \right)$$

Hipotesis pada pengujian *Jarque-Bera* seperti di bawah ini.

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Uji Jarque-Bera mempunyai distribusi *chi-kuadrat* dengan derajat bebas dua X_2^2 . Jika hasil Jarque-Bera lebih besar dari distribusi *chi-kuadrat* maka ditolak yang berarti tidak berdistribusi normal dan jika sebaliknya maka berarti berdistribusi normal. Cara lain menentukan residual berdistribusi normal yaitu dengan cara membandingkan nilai Sig. pada pengujian dengan nilai $\alpha(5\%)$. Kriteria penolakannya adalah jika nilai Sig. lebih besar dari $\alpha(5\%)$ maka residual dapat dikatakan berdistribusi normal, begitu juga sebaliknya.

2.11 Identifikasi Efek Heterokedastisitas pada Residual

Model *Autoregressive Conditional Heterokedasticity* (ARCH) merupakan model yang terjadi dalam keadaan varians tidak konstan. Varians dari residual yang tidak konstan sehingga bersifat heterokedastisitas. Uji ARCH-*Lagrange*

Multiplier digunakan untuk mengetahui ada tidaknya gejala heterokedastisitas pada suatu data deret waktu.

Hipotesis yang digunakan dalam pengujian ini adalah:

$H_0: \alpha_1 = \dots = \alpha_p = 0$ (tidak ada efek ARCH pada residualnya).

H_1 : minimal ada satu $\alpha_i \neq 0$, untuk $i=1, 2, \dots, p$ (ada efek ARCH dalam residualnya).

Taraf Signifikansi: $\alpha=5\%$

Statistik Uji:

$$LM = \frac{NT}{2(T-1)} \sum_{i=1}^N \left[\frac{T^2 \sigma_i^2}{\sigma^2} - 1 \right]^2$$

dengan,

T: jumlah unit *time series*

N: jumlah unit *cross section*

σ_i^2 : variansi residual persamaan ke-i

σ^2 : variansi residual persamaan system

Kriteria Uji: H_0 ditolak jika $LM > X_{(1;\alpha)}^2$

2.12 Model ARCH dan GARCH

Pada umumnya pemodelan data runtun waktu harus memenuhi syarat asumsi varian yang konstan (homokedastisitas). Tidak sedikit pula data runtun waktu yang memiliki masalah heterokedestisitas. Oleh karena itu, digunakan analisis model yang dapat mengatasi masalah heterokedastisitas yaitu ARCH

(*Autoregressive Conditional Heteroscedasticity*) dan GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*).

2.12.1 Model ARCH

Model ARCH pertama kali dikenalkan oleh Engle tahun 1982. Model ini digunakan untuk memodelkan volatilitas residual yang sering terjadi pada data-data keuangan. Bentuk umum model ARCH(p) adalah sebagai berikut.

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2$$

dengan,

$$\alpha_0 > 0, \alpha_i \geq 0, \text{ untuk } i = 1, \dots, p$$

p : ordo ARCH

α : parameter ARCH

2.12.2 Model GARCH

Pada tahun 1986 Bollorseev memperkenalkan model GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*) yang merupakan perluasan dari model ARCH. GARCH merupakan salah satu pendekatan untuk memodelkan runtun waktu dengan kondisi *error* bervariasi menurut waktu. GARCH dianggap memberikan hasil yang lebih sederhana karena menggunakan lebih sedikit parameter sehingga mengurangi tingkat kesalahan dalam perhitungan. Bentuk umum dari model GARCH(p, q) adalah sebagai berikut.

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_q \sigma_{t-q}^2$$

dengan,

$\alpha_0 > 0, \alpha_i \geq 0$, untuk $i = 1, \dots, p$ dan $\beta_j \geq 0$, untuk $j = 1, \dots, q$.

p : ordo ARCH

q : ordo GARCH

α : parameter ARCH

β : parameter GARCH

Jika $q = 0$ maka model juga disebut model ARCH, jika $p = q = 0$ maka akan didapat proses *white noise*, dan $p = q = 1$ maka diperoleh estimasi GARCH (1,1).

2.17 Penentuan Model Terbaik

Penentuan model terbaik dapat digunakan untuk menilai kualitas model diantaranya adalah menggunakan *Akaike Information Criterion* (AIC). Model terbaik adalah model yang memiliki nilai AIC paling kecil. Perhitungan AIC didefinisikan sebagai berikut:

$$AIC = n \ln \sigma_a^2 + 2M$$

Dengan M merupakan jumlah parameter yang ditaksir, n merupakan banyaknya data, dan σ_a^2 merupakan nilai varians residual dengan estimasi *maximum likelihood*.

2.18 Penentuan Akurasi Peramalan

Nilai akurasi menunjukkan seberapa dekat nilai variabel terikat yang diprediksi oleh model dengan data aktual. Setelah mendapatkan model terbaik, maka selanjutnya dilakukan peramalan. Namun, dalam peramalan dengan menggunakan model terbaik akan tetap memiliki error pada hasil ramalannya.

Oleh karena itu, setelah mendapat hasil peramalan perlu dilakukan evaluasi peramalan. Salah satu cara yang digunakan untuk mengetahui *error* adalah *Mean Absolute Percentage (MAPE)*. *Mean Absolute Percentage (MAPE)* digunakan untuk mengukur kesalahan nilai dugaan dalam bentuk persentase rata-rata *absolute* kesalahan. Rumus untuk menentukan nilai MAPE seperti berikut ini:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \times 100\%$$

dengan,

Y_t = nilai aktual pada waktu ke-t

\hat{Y}_t = nilai peramalan pada waktu ke-t

n = banyak data

