

BAB II

LANDASAN TEORI

Landasan teori sangat penting dalam setiap penelitian dikarenakan landasan teori merupakan suatu dasar yang kuat dalam sebuah penelitian yang akan dilaksanakan. Yang dibahas pada bagian ini adalah teori-teori mengenai investasi, pasar modal, saham, volatilitas, transformasi *wavelet* dan model GARCH.

2.1 Investasi dan Pasar Modal

2.1.1 Investasi

Investasi merupakan suatu penanaman modal dalam jangka waktu lama serta mengharapkan keuntungan pada masa mendatang [13]. Hakikatnya investasi adalah penempatan sejumlah dana saat ini dengan mengharapkan dana tersebut dapat menjadikannya keuntungan di masa yang akan datang [14]. Dengan demikian, investasi memiliki arti sebagai suatu kegiatan penempatan dana pada satu atau lebih aset pada selang waktu tertentu dengan mengharapkan bahwa suatu saat akan mendapatkan penghasilan atau peningkatan nilai investasi tersebut.

2.1.2 Pasar Modal

Pasar modal merupakan suatu kegiatan yang menyangkut penawaran umum, perdagangan efek, perusahaan publik yang berkaitan dengan efek yang diterbitkan serta lembaga dan profesional yang berkaitan dengan efek [15]. Efek merupakan suatu surat berharga, yaitu surat pengakuan hutang, tanda bukti hutang, obligasi, saham, unit penyeteroran kontrak investasi kolektif, surat berharga komersial, kontrak berjangka atas efek dan setiap derivatif dari efek.

Secara umum pasar modal dapat diartikan sebagai tempat pertemuan antara para penjual dan pembeli untuk memperoleh sebuah keuntungan. Bursa efek (*stock exchange*) merupakan pihak penyelenggara dan penyedia sistem serta sebagai sarana guna mempertemukan para penjual dan pembeli efek yang bertujuan memperdagangkan efek diantara mereka [15]. Pasar modal di Indonesia semakin berkembang serta telah diakui oleh negara dan dilindungi oleh hukum. Namun sayang pasar modal ini tidak banyak dikenal oleh masyarakat awam yang tidak

masuk dalam dunia investasi. Oleh karena itu, pasar modal harus dikenalkan lebih dalam kepada masyarakat melalui sosialisasi dan edukasi untuk meningkatkan minat masyarakat berinvestasi.

2.2 Saham dan Indeks Harga Saham Gabungan

2.2.1 Saham

Saham adalah suatu instrumen pasar modal dalam bentuk surat bukti kepemilikan atas kepemilikan suatu perusahaan yang telah melakukan penawaran umum (*go public*) dalam bentuk nominal atau presentasi tertentu [16]. Saham merupakan surat berharga yang berguna menunjukkan keikutsertaan atau kerjasama para investor didalam perusahaan sebagai penanam modal serta tanda kepemilikan sebuah perusahaan [17]. Oleh karena itu dapat disimpulkan bahwa saham adalah instrumen pasar modal dalam bentuk surat berharga yang menyatakan bukti suatu kepemilikan/keikutsertaan seorang investor dalam sebuah perusahaan.

2.2.2 Indeks Harga Saham Gabungan

Indeks saham merupakan indikator dalam bentuk angka indeks pada harga saham, pelaku pasar seperti investor merupakan penentu dalam pergerakan saham yang sesuai dengan permintaan dan penawaran saham sehingga bersangkutan dalam pasar modal. Sedangkan, suatu indikator atau cerminan pergerakan harga saham yang digunakan sebagai bahan pertimbangan para investor dalam melakukan investasi disebut indeks harga saham. Indeks Harga Saham Gabungan (IHSG) adalah indeks yang mengukur kinerja semua harga saham yang telah dicatat dipapan utama dan papan pengembangan Bursa Efek Indonesia (IDX) dan merupakan sebuah indikator kinerja pasar modal apakah sedang mengalami peningkatan (*bullish*) atau sedang mengalami penurunan (*barrish*). Disebutkan bahwa apabila kondisi perekonomian suatu negara baik maka IHSG tentunya menunjukkan adanya *trend* yang meningkat.

2.3 Deret Runtun Waktu (*Time Series*)

Time series adalah suatu prosedur dalam statistika diterapkan untuk mendapatkan keputusan dalam suatu perencanaan tertentu dengan melakukan peramalan struktur probabilitas keadaan yang terjadi di masa yang akan datang

[18]. *Time series* (runtun waktu) adalah analisis sekumpulan data-data pada masa lampau yang berguna untuk mengetahui atau meramalkan kondisi yang akan datang. Peramalan yang baik membutuhkan berbagai macam informasi (data) yang cukup banyak dan diamati dalam periode waktu yang relatif cukup panjang, sehingga dari hasil analisis tersebut dapat diketahui sampai berapa besar fluktuasi yang terjadi dan faktor-faktor apa saja yang mempengaruhi terhadap perubahan tersebut. Data *time series* merupakan data yang dikumpulkan, dicatat atau diobservasi sepanjang waktu secara berurutan. Periode waktu observasi dapat berbentuk tahun, kuartal, bulan, minggu dan dibeberapa kasus dapat juga hari atau jam.

2.3.1 *Return*

Return saham merupakan tingkat kembalian keuntungan yang diperoleh investor atas suatu investasi yang dilakukan [14]. Hasil yang diperoleh dari investasi oleh para investor sedang dipertaruhkan nilainya sekarang untuk mendapatkan nilai yang diharapkan di masa yang akan datang. *Return* dapat dibedakan menjadi dua yaitu *return* aktual (*actual return*) dan *return* ekspektasi (*expected return*). *Return* aktual (*actual return*) adalah *return* yang dihitung berdasarkan data lampau atau data historis. *Return* ekspektasi (*expected return*) adalah *return* yang diharapkan akan diperoleh oleh investor dimasa mendatang.

Return realisasi dibagi menjadi beberapa macam dengan kegunaan masing-masing. Terdapat empat macam *return* realisasi yang sering digunakan yaitu *return* total (*simple net return*), *return* relatif (*simple gross return*), *return* kumulatif (*annualized return*) dan *log return* (*continuously compounded return*) [19].

Misalnya P_t adalah harga sekuritas pada waktu (periode) t dan tidak ada pembayaran dividen pada periode ini. *Return* total (*simple net return*) dimana R_t pada sekuritas antara periode $t - 1$ sampai dengan t didefinisikan sebagai berikut:

$$R_t = \frac{P_t}{P_{t-1}} - 1 \quad (2.1)$$

R_t merupakan *capital gain/capital loss*. Apabila hasil *return* bernilai positif maka dinamakan *capital gain* sedangkan apabila hasil *return* bernilai negatif dinamakan *capital loss*.

Return relatif (*simple gross return*) dirumuskan sebagai $1 + R_t$. *Return* relatif dari sekuritas selama k periode terakhir yaitu dari periode $t - k$ sampai dengan periode ke- t ditulis $1 + R_t(k)$ adalah sama dengan hasil kali dengan k *return* periode tunggal dari $t - k + 1$ sampai dengan periode ke- t . Apabila dirumuskan sebagai berikut:

$$\begin{aligned} 1 + R_t(k) &= (1 + R_t) \times (1 + R_{t-1}) \times \dots \times (1 + R_{t-k+1}) \\ &= \frac{P_t}{P_{t-1}} \times \frac{P_{t-1}}{P_{t-2}} \times \dots \times \frac{P_{t-k+1}}{P_{t-k}} \\ &= \frac{P_t}{P_{t-k}} \end{aligned} \quad (2.2)$$

Apabila *net return* selama k periode terakhir sebagai berikut:

$$R_t(k) = \frac{P_t}{P_{t-k}} - 1 \quad (2.3)$$

Return multiperiodik seperti diatas dinamakan *compound return* (*return* majemuk).

Return yang masing-masing sekuritasnya ditampilkan dalam bentuk tahunan (*annualized*) yang menyatakan *return* sekuritas bersangkutan dalam 1 tahun dirumuskan sebagai berikut :

$$[R_t(k)] = \left[\prod_{j=0}^{k-1} (1 + R_{t-j}) \right]^{1/k} - 1 \quad (2.4)$$

Dengan memanfaatkan Deret Taylor orde 1, diperoleh rumus pendekatan berikut:

$$[r_t(k)] \approx \frac{1}{k} \sum_{j=1}^{k-1} r_{t-j} \quad (2.5)$$

Kesulitan manipulasi matematis yang dihadapi dalam perhitungan *return* diatas menggunakan rata-rata geometri membawa kita pada pengertian *continuous compounding (log return)*. r_t sebagai ukuran majemuk yang dirumuskan sebagai berikut [4]:

$$\begin{aligned} r_t &= \ln(1 + R_t) \\ &= \ln \frac{P_t}{P_{t-1}} \end{aligned} \quad (2.6)$$

Dimana :

P_t : harga saham pada periode t
 P_{t-1} : harga saham pada periode $t - 1$
 t : return harian.

Log diatas menyatakan *logaritma natural* (logaritma dengan bilangan pokok e) dan bukan *log10* alasannya untuk kemudahan manipulasi matematika maka *return* yang digunakan dalam perhitungan ini adalah r_t [20].

2.3.2 Risiko

Hanya menghitung return saja untuk suatu investasi tidaklah cukup. Risiko dari investasi juga perlu diperhitungkan. Risiko investasi adalah ketidaksesuaian antara *expected return* (*return* yang diharapkan) dengan *actual return* (*return* aktual) yang berarti resiko merupakan penyimpangan dari fakta *return* yang diterima [21]. Sehingga dalam menghitung risiko investasi ditentukan dari tingkat penyimpangan *expected return*. *Return* dan risiko merupakan dua hal yang tidak terpisahkan, karena pertimbangan suatu investasi *trade-off* dari kedua faktor ini.

Risiko sering dihubungkan dengan penyimpanan atau deviasi dari *outcome* yang diterima dengan ekspektasi. Untuk *return* aktual (*actual return*) metode yang sering digunakan untuk mengukur risiko ini adalah standar deviasi yang mengukur penyimpangan nilai-nilai yang sudah terjadi dengan nilai rata-ratanya. Standar deviasi dapat dinyatakan sebagai berikut [19]:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}} \quad (2.7)$$

Dimana:

σ : standar deviasi

x_i : nilai ke- i

$\bar{x}$: nilai rata-rata

n : jumlah data

2.3.3 Volatilitas

Tingkat resiko menjadi pertimbangan dalam menginvestasikan modal, sehingga seorang investor menjadi penanggung resiko. Teori yang berkaitan dengan pengukuran resiko adalah volatilitas. Volatilitas secara bahasa mengandung arti tidak stabil, suatu kondisi dimana data bergerak naik turun, kadang secara ekstrem. Menurut Rosadi [22], untuk menggambarkan fluktuasi dari suatu data dikenal konsep volatilitas. Semakin tinggi volatilitas menunjukkan resiko yang semakin tinggi dan juga tingkat *return* yang tinggi, dengan mengetahui kadar volatilitas aset investasi yang dimiliki akan membuat investor lebih bijak dalam melakukan investasi.

Volatilitas juga dapat digunakan dalam peramalan keuangan dengan menggunakan data *time series*. Hal tersebut terkadang menyebabkan munculnya fenomena heteroksidastisitas. Diakibatkan oleh pergerakan pasar yang tiba-tiba berubah drastis, jika ada berita jelek, lalu akan kembali tenang beberapa waktu kemudian. Artinya data mengalami fluktuasi naik turun yang ekstrem, dalam bidang keuangan hal ini dinamakan sebagai *volatility clustering* [23].

2.4 Stasioneritas

Stasioneritas adalah suatu hasil sebuah pemrosesan data dimana nilai rata-ratanya (*mean*) dan variansinya dari faktor gangguan (*error*) tidak mengalami perubahan sepanjang waktu atau bisa dikatakan data tersebut selalu berjalan konstan dan sebaliknya, kemudian data hasil pemrosesan dinyatakan tidak stasioner apabila rata-ratanya (*mean*) dan variannya berubah sepanjang waktu atau berjalan tidak

konstan [24]. Sebuah model yang tidak stasioner akan menghasilkan ramalan dimana variansinya akan terus meningkat tanpa ada batasan sehingga hasil tidak sesuai harapan yang diinginkan. Maka syarat stasioneritas merupakan hal mutlak dalam menentukan suatu model runtun waktu.

Menurut Wei [25] suatu *time series* harus memenuhi syarat stasioneritas, dapat dibagi dua sebagai berikut:

1. Stasioner dalam rata-rata (*mean*)


Sebuah data *time series* dinyatakan stasioner dalam rata-rata jika sebuah data *time series* memiliki nilai rata-ratanya (*mean*) relatif konstan seiring berjalannya waktu sehingga dapat dinyatakan sebagai berikut:

$$\begin{aligned} E(Y_t) &= \mu \\ &= \frac{\sum_{i=1}^n x_i}{n} \end{aligned} \quad (2.8)$$

2. Stasioner dalam varian

Sebuah data *time series* dapat dinyatakan sebagai stasioner dalam varian jika bentuk data *time series* seiring berjalannya waktu tidak adanya perubahan variansinya dalam besarnya fluktuasi atau dikatakan fluktuasi data *time series* berjalan konstan sehingga dapat dinyatakan sebagai berikut:

$$\begin{aligned} Var(Y_t) &= E(Y_t - \mu)^2 \\ &= \sigma^2 \\ &= \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1} \end{aligned} \quad (2.9)$$



Gambar 2.2 Plot Data *Time Series* yang Stasioner

Sumber : Wei [25]

Gambar grafik diatas merupakan plot data time series stasioner. Grafik dibuat plot antara observasi dengan waktu jika terlihat memiliki rata-rata (*mean*) dan varians konstan, maka data tersebut dapat disimpulkan stasioner. Data *time series* dikatakan stasioner jika rata-rata (*mean*) dan varians serta kovarian pada setiap *lag* adalah tetap sama pada setiap waktu. Untuk menguji kestasioneritas data *time series* maka perlunya dilakukan dengan menggunakan Uji *Augmented Dickey Fuller* (ADF). Jika data *time series* tidak memenuhi kriteria tersebut maka data dikatakan tidak stasioner, dengan kata lain data *time series* dikatakan tidak stasioner jika rata-ratanya maupun variannya tidak konstan atau berubah-ubah sepanjang waktu. Apabila data tidak stasioner maka perlunya dilakukan modifikasi dengan salah satu metodenya yaitu differensi (*defferencing*).

2.4.1 *Autocorrelation Function* (ACF)

Alat utama untuk mengidentifikasi model dari data akan diramalkan adalah dengan menggunakan Fungsi Autokorelasi atau *Autocorrelation Function* (ACF) dan Fungsi Autokorelasi Parsial atau *Partial Autocorrelation Function* (PACF). Korelasi adalah hubungan linier antara dua variabel, sedangkan autokorelasi adalah suatu keadaan dimana terdapat ketergantungan (hubungan) antara nilai-nilai suatu *time series* yang sama pada periode berbeda [26].

Pada *Autocorrelation Function* (ACF) menjelaskan seberapa besar korelasi data yang berurutan dalam runtun waktu, yang merupakan perbandingan antara kovarian pada *lag k* dengan variannya. Jika nilai ACF pada setiap kelambanan mendekati atau sama dengan 0 maka datanya adalah stasioner, jika sebaliknya nilai koefisien ACF relatif tinggi dan mendekati 1 maka data tidak stasioner. Pengujian koefisien autokorelasi:

$H_0: \rho_k = 0$ (Koefisien autokorelasi tidak berbeda secara signifikan dengan nol)

$H_1: \rho_k \neq 0$ (Koefisien autokorelasi berbeda secara signifikan dengan nol)

Dengan demikian ACF pada kelambanan k (ρ_k) dapat ditulis sebagai berikut [27]:

$$\rho_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y}) (Y_{t+k} - \bar{Y})}{\sum_{t=1}^{n-k} (Y_t - \bar{Y})^2} \quad (2.10)$$

Dimana :

ρ_k : koefisien ACF pada *lag* ke- k

Y_t : nilai variabel Y pada waktu t

$\bar{Y}$: nilai rata-rata Y

n : jumlah data observasi

k : periode *time series*

Stasioner tidaknya data runtun waktu (*time series*) dapat dilakukan melalui uji statistik berdasarkan *standar error* (*se*).

$$\rho_k \pm 1,96(se) \text{ atau } \rho_k \pm 1,96 \left(\sqrt{1/n} \right) \quad (2.11)$$


Apabila nilai koefisien ACF (ρ_k) terletak di dalam interval tersebut maka menerima hipotesis nol H_0 bahwa nilai ρ_k sama dengan nol, berarti data stasioner. Tetapi jika nilai ρ_k terletak diluar interval maka menolak hipotesis H_0 bahwa ρ_k sama dengan nol atau dengan kata lain data tidak stasioner.

2.4.2 Partial Autocorrelation Function (PACF)

Pada *Partial Autocorrelation Function* (PACF) digunakan untuk mengukur tingkat keeratan korelasi antara Y_t dan Y_{t+k} , apabila pengaruh $lag\ t + 1, t + 2, \dots, t + k - 1$ dianggap terpisah. Dengan adanya PACF berguna untuk mengetahui hubungan antara Y_t dan Y_{t+k} dengan turut memperhitungkan pengaruh dari Y_t yang berada diantara data tersebut. Koefisien autokorelasi PACF diberi notasi ϕ_{kk} .

Pada *Partial Autocorrelation Function* (PACF) dalam *time series* model Box-Jenkins ARIMA digunakan untuk memilih satu atau beberapa model ARIMA yang sesuai untuk data *time series* yang sedang diamati. Koefisien PACF berorde p didefinisikan sebagai koefisien autoregressif terakhir dari model $AR(p)$. Apabila terdapat p autokorelasi parsial yang signifikansinya berbeda dari nol maka diasumsikan proses tersebut yaitu proses $AR(p)$. Sehingga apabila autokorelasi parsial menurun mendekati nol secara ekponensial maka diasumsikan proses tersebut yaitu proses $MA(p)$.

Selain menggunakan uji diatas, untuk mengetahui data tersebut stasioner maka dapat dilihat juga pada grafik yang terbentuk. Apabila setelah lag 2 dan 3 pada grafik menurun mendekati nol maka data tersebut telah stasioner pada tingkat level (nol) [25].



Gambar 2.3 Pola Autokorelasi Tidak Stasioner dan Stasioner

Sumber : M.T. Kurnia, E.H. Nugrahani dan H. Sumarno [10]

2.4.3 Uji Augmented Dickey Fuller (ADF)

Uji *Augmented Dickey Fuller* (ADF) merupakan salah satu uji yang sering digunakan dalam pengujian data stasioner, yaitu dengan melihat apakah terdapat unit *root* dalam model atau tidak. Indikasi terdapatnya *unit root* adalah *random walk* artinya data *time series* tidak stasioner pada ragam. Pengujian stasioner dengan *Augmented Dickey Fuller* (ADF) dapat dinyatakan dalam persamaan berikut [28]:

$$t - \text{hitung} = \frac{\hat{\rho}}{se(\hat{\rho})} \quad (2.12)$$

Dengan $\hat{\rho}$ merupakan korelasi dugaan dari ρ dan $se(\hat{\rho})$ merupakan error dari dugaan ρ . Pengujian dilakukan dengan menguji hipotesis ADF sebagai berikut:

$H_0: \gamma = 0$ (terdapat akar unit berarti data tidak stasioner)

$H_1: \gamma < 0$ (tidak terdapat akar unit berarti data stasioner)

Dalam persamaan hipotesis nol ditolak jika nilai statistik uji ADF memiliki nilai kurang lebih negatif dibandingkan dengan nilai daerah kritis. Jika hipotesis nol ditolak, data bersifat stasioner dan sebaliknya.

2.5 Model Box – Jenkins (ARIMA)

Model Box-Jenkins merupakan salah satu teknik peramalan model time series yang hanya berdasarkan perilaku data variabel yang diamati. Model *Box-Jenkins* ini secara teknis dikenalkan oleh Box dan Jenkins pada tahun 1977 sebagai model *Autoregressive Integrated Moving Average* (ARIMA) [29]. Alasan utama penggunaan teknik Box-Jenkin karena gerakan variabel-variabel ekonomi yang diteliti seperti pergerakan nilai tukar, harga saham, harga bahan pokok, dan inflasi. Teknik Box-Jenkin sebagai teknik peramalan berbeda dengan kebanyakan model peramalan yang ada. Model Box-Jenkin terdiri dari beberapa model yaitu: *autoregressive* (AR), *moving average* (MA), dan *autoregressive moving average* (ARMA).

2.5.1 Model Autoregressive (AR)

Model AR menunjukkan nilai prediksi variabel dependen Y_t hanya merupakan fungsi linier dari sejumlah Y_t aktual sebelumnya. Misalnya nilai variabel dependen Y_t hanya dipengaruhi oleh nilai variabel tersebut satu periode

sebelumnya atau kelambanan pertama maka model tersebut disebut model *autoregressive* tingkat pertama atau disingkat AR(1). Persamaan model AR(1) dapat ditulis sebagai berikut [30]:

$$Y_t = \mu + \phi_1 Y_{t-1} + \varepsilon_t \quad (2.13)$$

dengan Y_t merupakan nilai variabel pada waktu ke- t dan Y_{t-1} merupakan *lag* pertama dari Y serta ε_t adalah nilai *error* pada saat ke- t . Secara umum bentuk model umum *autoregressive* AR dapat dinyatakan dalam persamaan sebagai berikut:

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.14)$$

dimana:

Y_t : nilai variabel pada waktu ke- t

Y_{t-p} : *lag* dari Y pada waktu ke- $t - p$

μ : rata-rata variabel acak

$\phi_1 \dots \phi_p$: koefisien parameter *autoregresif* (AR) pada- p

ε_t : nilai *error* pada saat ke- t

p : orde AR

2.5.2 Model Moving Avarage (MA)

Model MA ini menyatakan bahwa nilai prediksi variabel dependent Y_t hanya dipengaruhi oleh nilai *error* residual periode sebelumnya pada *lag* ke- q . Misalnya jika nilai variabel dependen Y_t hanya dipengaruhi oleh nilai residual satu periode sebelumnya maka disebut dengan model MA tingkat pertama atau disingkat dengan MA(1) dapat ditulis dalam bentuk persamaan sebagai berikut [30]:

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (2.15)$$

Secara umum bentuk model dari *moving average* dapat dinyatakan dalam bentuk persamaan sebagai berikut :

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.16)$$

Dimana:

Y_t : nilai variabel pada waktu ke- t

- ε_t : nilai *error* residual pada saat ke- t ,
 μ : rata-rata variabel acak
 $\theta_1 \dots \theta_q$: koefisien parameter *moving average* (MA) pada- q
 ε_{t-q} : nilai *error* residual pada masa lalu, $q = 1, 2, 3, \dots$
 q : orde MA.

Model MA dalam persamaan (2.15) seperti model AR persamaan (2.13) kecuali variabel dependen Y tergantung dari nilai residual sebelumnya dan tidak tergantung dengan nilai variabel dependen sebelumnya. Model MA adalah model prediksi variabel dependen Y berdasarkan residual sebelumnya sedangkan model AR memprediksi variabel Y berdasarkan pada nilai Y sebelumnya.

2.5.3 Model Autoregressive Moving Average (ARMA)

Model gabungan AR dan MA disebut ARMA. Model ARMA yang memiliki nilai variabel Y_t dipengaruhi oleh kelambanan (*lag*) pertama dan nilai pertama *error* residual data sebelumnya maka modelnya disebut dengan model ARMA(1,1). Model ARMA(1,1) dapat ditulis dalam bentuk persamaan sebagai berikut [30]:

$$Y_t = \mu + \phi_1 Y_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (2.17)$$

Secara umum bentuk model dari ARMA dapat ditulis dalam bentuk persamaan sebagai berikut:

$$Y_t = \mu + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (2.18)$$

Dimana:

- Y_t : nilai variabel acak saat t
 ϕ_p : parameter *autoregresif*
 p : Orde AR
 μ : parameter konstan
 θ_q : parameter *moving average*
 q : Orde MA
 ε_t : nilai *error* pada saat t

2.5.4 Model Autoregressive Integrated Moving Average (ARIMA)

Model AR, MA dan ARMA mensyaratkan data *time series* yang diamati mempunyai sifat *stasioner*. Data *time series* dikatakan stasioner jika memenuhi tiga kriteria yaitu jika data *time series* mempunyai rata-rata, varian yang konstan. Data *time series* sering tidak *stasioner* sehingga perlu di diferensi (*difference*). Model dengan data yang *stasioner* melalui proses diferensi ini disebut ARIMA. Jika data stasioner pada proses diferensi d kali dan mengaplikasikan ARMA(p, q) maka model ARIMA(p, d, q) dimana p adalah tingkat AR, d tingkat proses membuat data menjadi *stasioner* (*difference*) dan q merupakan tingkat MA. Bentuk umum model ARIMA dinyatakan dalam persamaan :

$$\phi_p(B)(1 - B)^k Y_t = \mu + \theta_q(B)\varepsilon_t \quad (2.19)$$

Dimana:

Y_t : nilai variabel acak saat t

ϕ_p : parameter *autoregresif*

p : Orde AR

B : operator shift mundur

k : *differencing*

μ : parameter konstan

θ_q : parameter *moving average*

q : Orde MA

ε_t : nilai *error* pada saat t

dengan ε_t adalah proses *white noise* dengan mean 0 dan varian σ^2 . Deret waktu Y_t juga berdistribusi normal sebagai proses *white noise* dengan mean 0 dan varian σ^2 . Model ARIMA(p, d, q) merupakan model umum dari regresi deret waktu, sebab ARIMA($p, 0, 0$) sama dengan AR(p), ARIMA($0, 0, q$) sama dengan MA(q), dan ARIMA($p, 0, q$) sama dengan ARMA(p, q).

2.5.5 Identifikasi Model

Hal pertama yang dilakukan pada tahap ini adalah apakah *time series* bersifat *stasioner* atau *nonstasioner* dan bahwa aspek-aspek AR dan MA hanya berkenaan dengan *time series* yang stasioner [31]. Kestasioneran suatu *time series*

dapat dilihat dari plot ACF yaitu koefisien autokorelasinya menurun menuju nol dengan cepat, biasanya setelah *lag* ke-2 atau ke-3. Bila data tidak *stasioner* maka dapat dilakukan pembedaan atau *differencing*, orde pembedaan sampai deret menjadi *stasioner* dapat digunakan untuk menentukan nilai d pada (p, d, q) ARIMA. Model AR dan MA dari suatu *time series* dapat dilakukan dengan melihat grafik ACF dan PACF. Jika terdapat *lag* autokorelasi sebanyak q yang berbeda dari nol secara signifikan maka prosesnya adalah $MA(q)$. Kemudian apabila terdapat *lag* autokorelasi parsial sebanyak p yang berbeda dari nol secara signifikan maka prosesnya adalah $AR(p)$. Secara umum jika terdapat *lag* autokorelasi parsial sebanyak p yang berbeda dari nol secara signifikan, terdapat *lag* autokorelasi sebanyak q yang berbeda dari nol secara signifikan dan d pembedaan maka prosesnya adalah ARIMA (p, d, q) . Tabel 2.1 merupakan identifikasi order model AR dan MA dengan plot ACF dan PACF, yaitu [32]:

Tabel 2.1 Karakteristik ACF dan PACF dalam penentuan model ARIMA

Proses	Pola ACF	Pola PACF
AR(p)	Menurun menuju nol (secara eksponensial) atau mengikuti pola gelombang sinus (<i>Dies down</i>)	Terputus seketika menuju nol setelah <i>lag</i> p (<i>cuts off after lag</i> p)
MA(q)	Terputus seketika menuju nol setelah <i>lag</i> q (<i>cuts off after lag</i> q)	Menurun menuju nol secara eksponensial) atau mengikuti gelombang sinus (<i>Dies down</i>)
ARMA(p, q)	Menurun menuju nol (secara eksponensial)	Menurun menuju nol (secara eksponensial)

Pada Tabel 2.1 karakteristik ACF dan PACF membedakan ketiga model ARIMA, adalah sebagai berikut [32]:

1. Proses $AR(p)$

Semua proses AR yang *stasioner* memiliki ACF teoritis yang meluruh menuju nol. Peluruhan ini dapat berbentuk eksponensial sederhana, koefisien autokorelasi sering pula berganti tanda menunjukkan pola gelombang sinus atau bentuk peluruhan lain yang lebih kompleks, namun selalu bergerak menuju nol.

Sementara, PACF teoritis dari proses AR memiliki *spike* sehingga terputus (*cuts off*) menuju nol setelah lag p yang merupakan ordo dari proses AR tersebut. Dalam praktik, untuk model AR non musiman, nilai p umumnya tidak lebih dari dua atau tiga.

2. Proses MA(q)

ACF teoritis proses MA terputus seketika (*cuts off*) menuju nol setelah terjadi *spike* hingga lag q yang merupakan ordo dari proses MA. Namun, PACF teoritisnya meluruh menuju nol setelah lag q . peluruhan ini dapat berbentuk eksponensial sederhana maupun menunjukkan pola gelombang sinus yang mengecil. Praktiknya, untuk model MA non musiman, nilai q umumnya tidak lebih dari dua.

3. Proses ARMA(p, q)

Proses campuran ARMA memiliki sifat campuran antara AR dan MA. ACF teoritisnya meluruh menuju nol setelah lag $(q - p)$ yang pertama, baik secara eksponensial ataupun berbentuk gelombang sinus. PACF teoritisnya meluruh menuju nol setelah lag $(p - q)$ yang pertama. Dalam praktik, untuk model runtun waktu non musiman, nilai p dan q umumnya tidak lebih dari dua.

2.6 Heteroskedastisitas (*Heteroscedasticity*)

Menurut Gujarati [32], variansi setiap *error* tergantung nilai yang dipilih dari variabel yang diperjelas. Suatu nilai *variable error* ε_i mempunyai varians yang konstan dinamakan homokedastisitas sehingga asumsi homokedastisitas dinyatakan dalam persamaan berikut ini:

$$E(\varepsilon_i) = \sigma^2 \quad (2.20)$$

Sedangkan, suatu nilai *variable error* ε_i mempunyai varian yang tidak konstan atau heteroskedastisitas. Adanya heteroskedastisitas ini dapat dinyatakan sebagai berikut:

$$E(e_i) = \sigma_i^2, \quad i = 1, 2, \dots, n \quad (2.21)$$

dengan ε_i merupakan *error* dan $i = 1, 2, \dots, n$.

Model regresi dengan heteroskedastisitas sangat berpengaruh pada estimator *Ordinary Least Squares* (OSL). Oleh karena itu sangat penting untuk mengetahui apakah suatu model regresi mengandung unsur heteroskedastisitas atau tidak. Cara yang paling cepat dan dapat digunakan untuk menguji masalah heteroskedastisitas adalah dengan mendeteksi pola residual melalui grafik. Jika residual mempunyai variansi yang sama (homokedastisitas) maka tidak mempunyai pola yang pasti dari residual. Sebaliknya jika residual mempunyai sifat heteroskedastisitas, residual ini akan menunjukkan pola tertentu.

2.6.1 Model Autoregressive Conditional Heteroscedasticity (ARCH)

Tingginya volatilitas data perlu dibuat suatu model pendekatan tertentu untuk mengukur masalah volatilitas residual. Salah satu pendekatan untuk memprediksi volatilitas varian residual adalah dengan memasukan variabel independen yang mampu memprediksi volatilitas residual tersebut. Model yang mengasumsikan bahwa varians residual tidak konstan dalam data *time series* yang dikembangkan oleh Engle tersebut disebut *Model Autoregressive Conditionally Heteroskedasticity* (ARCH) [2]. Bentuk model regresi sederhana sebagai berikut:

$$Y_t = \beta_0 + \beta_1 X_1 + \varepsilon_t \quad (2.22)$$

Dimana, Y merupakan variabel dependen, X merupakan variabel independen, ε merupakan variabel *gangguan* atau *error*. Heteroskedastisitas terjadi karena data *time series* menunjukkan unsur volatilitas. Dengan kondisi seperti ini maka varian variabel gangguan dari model akan sangat tergantung dari volatilitas variabel gangguan periode sebelumnya. Dengan kata lain varian variabel gangguan sangat dipengaruhi oleh variabel gangguan periode sebelumnya. Persamaan varian variabel gangguan dalam model ARCH ini dapat ditulis sebagai berikut:

$$h_t^2 = \alpha_0 + \alpha_1 h_{t-1}^2 \quad (2.23)$$

Persamaan (2.23) menyatakan bahwa varian variabel gangguan yakni h_t^2 mempunyai dua komponen yaitu konstan dan variabel gangguan periode lalu (*lag*) yang diasumsikan merupakan kuadrat dari variabel gangguan periode lalu. Model dari variabel gangguan ε_t tersebut adalah heteroskedastisitas yang bersyarat

(*Conditionally Heteroskedasticity*) pada variabel gangguan ε_{t-1} . Dengan mengambil *conditionally heteroskedasticity* dari ε_t maka dapat mengestimasi parameter β_0 dan β_1 secara efisien. Jika varian dari variabel gangguan ε_t tergantung hanya dari volatilitas variabel gangguan kuadrat satu periode yang lalu sebagaimana dalam persamaan (2.23) model ini disebut dengan ARCH(1). Dengan demikian secara umum model ARCH(p) dapat dinyatakan dalam persamaan berikut [25]:

$$h_t^2 = \alpha_0 + \alpha_1 h_{t-1}^2 + \alpha_1 h_{t-2}^2 + \cdots + \alpha_p h_{t-p}^2 \quad (2.24)$$

Dimana:

h_t^2 : variansi residual pada waktu t

α_0 : komponen konstanta

α_p : parameter dari ARCH dengan orde p

ε_t : residual pada saat t

h_{t-p}^2 : kuadrat residual pada waktu $t-p$

2.6.2 Identifikasi Unsur ARCH

Data *time series* sering mengandung masalah *autokolerasi* dan juga mengandung *heteroskedastisitas* [25]. Ada beberapa uji yang akan dibahas untuk mendeteksi ada tidaknya unsur heteroskedastisitas didalam time series yang dikenal dengan ARCH didalam model regresi.

1. Uji Gangguan Kuadrat Melalui *Correlogram*

Unsur ARCH didalam model regresi bisa dilihat dari *correlogram* dari *error* kuadrat. Jika tidak ada unsur ARCH didalam *error* kuadrat maka *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) seharusnya adalah nol pada semua kelambanan atau secara statistik tidak signifikan. Sebaliknya jika ACF dan PACF tidak sama dengan nol maka model mengandung unsur ARCH. Uji ada tidaknya unsur ARCH dalam *error* kuadrat melalui ACF dan PACF dapat juga dianalisis melalui uji statistik dari *Ljung-Box*.

$$n(n+2) \left(\sum_{k=1}^m \frac{\rho_k^2}{n-1} \right) \sim \chi_m^2 \quad (2.25)$$

Dimana:

- n : banyaknya sampel
- m : panjangnya kelambanan (*lag*)
- ρ_k : koefisien ACF pada *lag* ke- k

Jika nilai statistik *Ljung-Box* lebih kecil dari nilai kritis statistik dari tabel distribusi *chi squares* X^2 maka *error* menunjukkan tidak adanya unsur ARCH. Sebaliknya jika nilai statistik *Ljung-Box* lebih besar dari tabel distribusi *chi squares* X^2 maka residual mengandung unsur ARCH.

2. Uji ARCH-Lagrange Multiplier (ARCH-LM)

Selain uji unsur ARCH dalam residual kuadrat melalui *correlogram*, Wei [25] telah mengembangkan uji untuk mengetahui masalah heteroskedastisitas dalam data *time series*, dikenal dengan ARCH. Ide dasar dari uji ini adalah bahwa varian variabel gangguan ε_{t-1}^2 bukan hanya merupakan fungsi variabel independen tetapi tergantung dari variabel kuadrat pada periode sebelumnya atau dapat ditulis sebagai berikut :

$$h_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_p \varepsilon_{t-p}^2 \quad (2.26)$$

Hipotesis nol tidak adanya unsur ARCH dalam persamaan (2.26) tersebut dapat diformulasikan sebagai berikut:

$$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_p = 0 \quad (\text{Tidak terdapat efek ARCH})$$

$$H_1: \alpha_i \neq 0, i = 1, 2, \dots, p \quad (\text{Terdapat efek ARCH})$$

Dengan hipotesis nol tersebut maka varian variabel gangguan ε_t^2 akan konstan sebesar α_0 . Jika gagal menolak hipotesis nol maka model tidak mengandung masalah ARCH dan sebaliknya jika kita menolak hipotesis nol maka model mengandung unsur ARCH. Adapun prosedur uji ARCH sebagai berikut :

- a. Estimasi persamaan (2.18) dengan metode OLS (*Ordinary Least Squares*) atau metode kuadrat terkecil dan mendapatkan residual ε_t serta residual kuadratnya ε_t^2 .
- b. Melakukan regresi residual kuadrat dengan *lag* residual kuadrat sebagaimana persamaan (2.26).

$$\varepsilon_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \cdots + \alpha_p \varepsilon_{t-p}^2 \quad (2.27)$$

Persoalan dalam uji ini adalah sampai seberapa panjang *lag* yang digunakan. Untuk itu bisa digunakan kriteria yang dikembangkan Akaike melalui *Akaike Information Creterion* (AIC) maupun dari *Schwarz Information Creterion* (SIC).

- c. Jika sampel adalah besar, menurut Wei [25] model persamaan (2.27) akan mengikuti distribusi *chi-squares* dengan *df* sebanyak p pada persamaan berikut:

$$(n - p)R^2 \sim \chi_p^2 \quad (2.28)$$

Jika *chi squares* (x) hitung $>$ dari nilai kritis *chi-squares* (x^2) pada derajat kepercayaan ($\alpha = 0,05$) hipotesis H_0 ditolak. Maka hal ini berarti paling tidak ada satu α dalam persamaan (2.27) secara statistik signifikan tidak sama dengan nol sehingga menunjukkan adanya masalah dalam model ARCH. Sebaliknya, apabila *chi squares* (x) hitung $<$ dari nilai kritis *chi squares* (x^2) pada derajat kepercayaan ($\alpha = 0,05$) maka hipotesis H_0 diterima, artinya varian residual adalah konstan sebesar α_0 sehingga model terbebas dari masalah ARCH.

2.6.3 Uji Normalitas

Uji normalitas adalah mengukur perbandingan data empirik dengan data berdistribusi normal teoritik yang memiliki *mean* dan standar deviasi yang sama dengan data empirik. Data terdistribusi normal adalah salah satu syarat data *parametrik* sehingga data memiliki karakteristik empirik yang mewakili populasi. Metode-metode uji normalitas antara lain adalah uji *kurtosis*, *skewness*, *chi-square* X^2 test, *Kolmogorov-Smirnov test*, *Jarque Bera* dan lain-lain.

1. Uji Jarque-Bera (JB)

Metode Jarque-Bera ini didasarkan pada sampel besar, menggunakan perhitungan skewness dan kurtosis. Adapun formula uji statistik JB sebagai berikut:

$$JB = n \left[\frac{S_k^2}{6} + \frac{(K - 3)^2}{24} \right] \quad (2.29)$$

dimana S_k = Koefisien *skewness* dan K = koefisien kurtosis

$$S_k = \frac{\frac{1}{n} \sum_{i=1}^N (X_i - \bar{X})^3}{\left(\frac{1}{n} \sum_{i=1}^N (X_i - \bar{X})^2 \right)^{\frac{3}{2}}} \quad (2.30)$$

$$K = \frac{\frac{1}{n} \sum_{i=1}^N (X_i - \bar{X})^4}{\left(\frac{1}{n} \sum_{i=1}^N (X_i - \bar{X})^2 \right)^2} \quad (2.31)$$

Jika suatu variabel didistribusikan secara normal maka nilai koefisien $S_k = 0$ dan $K = 3$. Oleh karena itu, jika residual terdistribusi secara normal maka diharapkan nilai statistik JB akan sama dengan nol. Nilai statistik JB ini didasarkan pada distribusi *Chi squares*. Jika nilai probabilitas ρ dari statistik JB besar atau dengan kata lain nilai statistik dari JB tidak signifikan maka kita gagal menolak hipotesis bahwa residual mempunyai distribusi normal karena nilai statistik JB mendekati nol. Sebaliknya jika nilai probabilitas ρ dari statistik JB kecil atau signifikan maka kita menolak hipotesis bahwa residual mempunyai distribusi normal karena nilai statistik JB tidak sama dengan nol. Data tidak normal dapat digunakan dalam peramalan volatilitas, data yang tidak normal dapat disebabkan karena terdapat nilai ekstrim pada data yang diteliti, seperti pada data saham yang memiliki fluktuasi yang tinggi [33].

2. Uji Korelasi Serial Residual Kuadrat

Uji lain yang dapat dilakukan adalah uji korelasi serial dari residual kuadrat sampai lag ke- m menggunakan statistik *Q Ljung-Box* yang dibandingkan dengan kuantil dari distribusi X_m^2 atau menggunakan plot fungsi autokorelasi/autokorelasi parsial dari residual kuadrat terstandarisasi.

2.6.4 Model *Generalized Autoregressive Conditionally Heteroskedasticity* (GARCH)

Model ARCH dari Robert Engle kemudian disempurnakan oleh Tim Bollerslev. Menurut Bollerslev [3] varian variabel gangguan tidak hanya tergantung dari residual periode lalu tetapi juga varian variabel gangguan periode lalu. Apabila varian residual periode lalu dalam persamaan (2.32) maka model ini dikenal dengan *Generalized Autoregressive Conditionally Heteroskedasticity* (GARCH). Untuk menjelaskan model GARCH maka menggunakan model regresi sederhana sebagai berikut:

$$Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t \quad (2.32)$$

Dimana, Y merupakan variabel dependen, X adalah variabel independen, ε adalah residual atau *error*. Sedangkan varian residualnya dengan model GARCH ini dapat ditulis dengan:

$$h_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j}^2 \quad (2.33)$$

Pada model GARCH tersebut varian residual h_t^2 tidak hanya dipengaruhi oleh residual periode yang lalu $\alpha_i \varepsilon_{t-i}^2$ tetapi juga varian residual periode yang lalu h_{t-j}^2 . Model residual dalam persamaan (2.33) disebut GARCH secara umum karena varian residualnya hanya dipengaruhi oleh residual periode sebelumnya dan varian residual periode sebelumnya. Secara umum model GARCH yakni GARCH (p, q) dapat dinyatakan melalui persamaan berikut:

$$h_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2 + \beta_1 h_{t-1}^2 + \dots + \beta_q h_{t-q}^2 \quad (2.34)$$

Untuk model GARCH (1,1) dapat dilihat pada persamaan sebagai berikut [4]:

$$h_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1}^2 \quad (2.35)$$

dimana:

h_t^2 : variansi dari residual pada waktu t

α_0 : komponen konstanta

α_p : parameter dari ARCH

ε_{t-p}^2 : kuadrat dari residual pada waktu $t - p$

β_q : parameter dari *GARCH*

h_{t-q}^2 : variansi dari residual pada saat $t - q$

Dimana p menunjukkan unsur ARCH dan q unsur GARCH, sebagaimana model ARCH, model GARCH tidak bisa diestimasi dengan OLS (*Ordinary Least Squares*) atau metode kuadrat terkecil, tetapi dengan menggunakan metode *maximum likelihood*.

2.7 Transformasi Wavelet

Wavelet adalah suatu fungsi matematika yang mempunyai bentuk sinyal seperti fungsi *sinus* dan *cosinus* serta terlokalisasi dalam domain waktu dan frekuensi serta membentuk basis ortogonal dalam $L^2(R)$ [9]. Representasi fungsi menggunakan *wavelet* menjadi lebih efisien karena fungsi *wavelet* terlokalisasi dalam domain waktu yang artinya pada saat nilai domain relatif besar, fungsi *wavelet* berharga nol. Selain itu, *wavelet* juga mampu merepresentasikan fungsi-fungsi yang bersifat tidak mulus. Hal ini karena basis dalam *wavelet* ditentukan oleh letak dan skala. Representasi *wavelet* pada bagian fungsi yang tidak mulus akan menggunakan panjang *support* yang sempit dan pada bagian fungsi yang mulus akan menggunakan *support* yang lebih lebar. Dengan demikian fungsi *wavelet* mempunyai panjang *support* yang bersifat adaptif secara lokal sehingga metode *wavelet* sangat cocok untuk memodelkan data-data yang berfluktuasi.

Fungsi *wavelet* merupakan fungsi basis yang dapat digunakan dalam merepresentasikan data atau fungsi-fungsi yang lain. Fungsi *wavelet* berbeda dengan fungsi normal, ataupun fungsi gelombang seperti *sinusoida*, dimana semuanya ditentukan dalam suatu domain waktu $(-1,1)$. *Wavelet* dibedakan menjadi dua jenis, yaitu *wavelet* ayah (ϕ) dan *wavelet* ibu (ψ) yang mempunyai sifat berikut [9]:

$$\int_{-\infty}^{\infty} \phi(x) dx = 1 \quad (2.36)$$

$$\int_{-\infty}^{\infty} \psi(x) dx = 0 \quad (2.37)$$

Keluarga *wavelet* dihasilkan dari *wavelet* ayah dan *wavelet* ibu melalui dilatasi diadik dan translasi integer yaitu :

$$\phi_{j,k}(x) = (2^j)^{\frac{1}{2}} \phi(2^j x - k) \quad (2.38)$$

$$\psi_{j,k}(x) = (2^j)^{\frac{1}{2}} \psi(2^j x - k) \quad (2.39)$$

Dimana $\psi_{j,k}(x)$ merupakan fungsi detil atau fungsi *wavelet* dan $\phi_{j,k}(x)$ merupakan fungsi skala atau fungsi *smooth*. Fungsi *wavelet* dapat dinyatakan sebagai kombinasi linear dari basis yang dibangun oleh *wavelet* atau dapat dituliskan dalam persamaan berikut:

$$f(x) = \sum_{k \in \mathbb{Z}} a_{j,k} \phi_{j,k}(x) + \sum_{k \in \mathbb{Z}} d_{j,k} \psi_{j,k}(x) \quad (2.40)$$

Dimana:

$$a_{j,k} = \int f(x) \phi_{j,k}(x) dx \quad (2.41)$$

$$d_{j,k} = \int f(x) \psi_{j,k}(x) dx \quad (2.42)$$


Dengan $a_{j,k}$ merupakan koefisien *smooth* dan $d_{j,k}$ merupakan koefisien *wavelet*. Persamaan (2.40) dapat dinyatakan sebagai fungsi transformasi *wavelet* dimana jumlahan sinyal *smooth* yang disimbolkan dengan S_j dan sinyal *wavelet* yang disimbolkan dengan D_j seperti pada persamaan (2.43) berikut dibawah ini:

$$f(x) = \sum_{k \in \mathbb{Z}} a_{j,k} \phi_{j,k}(x) + \sum_{k \in \mathbb{Z}} d_{j-1,k} \psi_{j-1,k}(x) + \dots + \sum_{k \in \mathbb{Z}} d_{j,k} \psi_{j,k}(x)$$

$$f(x) = S_j + D_{j-1} + D_{j-2} + \dots + D_1 \quad (2.43)$$

Transformasi *Wavelet* merupakan transformasi yang paling terkenal dan banyak digunakan dalam bidang citra digital, audio, kelistrikan dan hal-hal yang

berhubungan dengan penggunaan sinyal. Dalam *wavelet* kita dapat menemukan keluarga *wavelet* diantaranya Haar, Daubechies, Symmlet, Morlet, Coiflet dan lainnya. Diantara *wavelet* diatas yang banyak digunakan adalah *Wavelet* Haar dan *Wavelet* Daubechies. *Wavelet* Daubechies merupakan penyempurna dari *wavelet* haar yang memiliki panjang dua kali dari levelnya ($2N$). *Wavelet* Daubechies disingkat dengan db diikuti dengan jumlah levelnya, misalnya db4 untuk *wavelet* yang memiliki level 4. Dalam setiap level dari *Wavelet* Daubechies memiliki level dalam tingkatan dekomposisinya. Angka level dari *Wavelet* Daubechies menunjukkan berapa kali sinyal akan melakukan proses dekomposisi seperti disajikan pada gambar 2.4 sebagai berikut :



Gambar 2.4 Fungsi *Wavelet* Daubechies berdasarkan levelnya

Sumber : Imam S, Manyuk F & Eki E [34]

2.7.1 Transformasi *Wavelet* Diskrit

Transformasi *wavelet* yang telah dibahas pada bagian sebelumnya merupakan *Continue Wavelet Transform* (CWT). Koefisien-koefisien *wavelet* pada persamaan (2.40) diperoleh melalui proses integrasi, oleh karenanya nilai *wavelet* harus terdefinisi pada setiap $\in R$. Bentuk transformasi *wavelet* yang lain (2.44) *Discrete Wavelet Transform* (DWT) dimana nilai-nilai *wavelet* hanya terdefinisi pada titik-titik diskrit. Terdapat dua filer pembangunan pada DWT yaitu filter *wavelet* (ibu) dinotasikan dengan h dan filter skala (ayah) yang dinotasikan dengan g . Panjang suatu filter dinotasikan dengan L . Sebuah filter *wavelet* harus memenuhi tiga sifat dasar berikut [35]:

$$\sum_{l=0}^{L-1} h_l = 0$$

$$\sum_{l=0}^{L-1} h_l^2 = 1 \quad (2.45)$$

$$\sum_{l=0}^{L-1} h_l h_{l+2n} = \sum_{l=-\infty}^{\infty} h_l h_{l+2n} = 0 \quad (2.46)$$

Jika diberikan filter *wavelet* $\{h_l\}$ maka filter *smooth* $\{g_l\}$ didefinisikan sebagai berikut:

$$g_l = (-1)^{l+1} h_{L-1-l} \quad (2.47)$$

Filter skala akan diasumsikan memenuhi kondisi berikut :

$$\sum_{l=0}^{L-1} g_l = \sqrt{2} \quad (2.48)$$

$$\sum_{l=0}^{L-1} g_l^2 = 1 \quad (2.49)$$

$$\sum_{l=0}^{L-1} g_l g_{l+2n} = \sum_{l=-\infty}^{\infty} g_l g_{l+2n} \quad (2.50)$$

Syarat yang harus dipenuhi untuk memenuhi sifat-sifat tersebut adalah panjang filter L bernilai genap. Misalkan diberikan filter *wavelet* $h = (h_0, h_1, \dots, h_{L-1})$ dan $X = (X_1, \dots, X_n)$ adalah nilai fungsi X pada $x_1, \dots, x_n$. Syarat yang harus dipenuhi adalah $N = 2^J$ dengan J suatu bilangan bulat positif. Transformasi *wavelet* dengan DWT dapat dituliskan sebagai berikut:

$$W = \mathcal{W}X \quad (2.51)$$

dengan W adalah hasil transformasi dengan DWT dan $\mathcal{W}$ adalah matriks transformasi berukuran $n \times n$.

Elemen-elemen dari vektor W dalam hal tersebut didekomposisi menjadi $J + 1$ subvektor. Transformasi dengan DWT akan memetakan vektor $X = (X_1, \dots, X_n)$ ke vektor koefisien $W = (W_1, W_2, \dots, W_J, V_J)$ dengan $W_j, j = 1, 2, \dots, J$ memuat koefisien *wavelet* $d_{j,k}$ dan V_J memuat koefisien skala $a_{j,k}$. Koefisien *wavelet* yang bernilai besar mempunyai kontribusi besar dalam rekonstruksi fungsi sedangkan koefisien yang bernilai kecil mempunyai kontribusi kecil sehingga dapat diabaikan (dianggap nol). Dengan demikian, DWT dapat digunakan untuk proses *denoising* dengan mengabaikan koefisien-koefisien *wavelet* yang dianggap kecil.

Pendekatan klasik untuk *denoising* berasal dari analisis Fourier yang mengasumsikan bahwa *noise* merupakan bentuk lain dari getaran pada frekuensi tinggi. Dengan pemikiran ini, suatu *time series* pada dasarnya dapat didekomposisi kedalam bentuk gelombang sinus dari frekuensi yang berbeda dan apabila dilakukan proses penghilangan *noise*, maka data frekuensi rendah akan ditinggalkan dalam pola *time series*. Transformasi *Wavelet* ini untuk menghilangkan *noise* (*denoising*) mengasumsikan bahwa analisis *time series* pada resolusi yang berbeda mungkin dapat memisahkan antara bentuk sinyal asli (pola data sebenarnya) dengan *noise*-nya.

2.7.2 *Maximal Overlap Discete Wavelet Transform (MODWT)*

Pemfilteran dengan DWT sebagaimana pada persamanaan (2.51) tidak dapat dilakukan jika sampel yang diamati berukuran sebarang yang tidak dapat dinyatakan dalam bentuk 2^J dengan J bilangan bulat positif, sedangkan data *time series* tidak selalu memiliki banyak data kelipatan dua. Sebagai alternatif, perhitungan koefisien $d_{j,k}$ dan $a_{j,k}$ dapat dilakukan dengan *Maximal Overlap Discrete Wavelet Transform (MODWT)*. Keuntungan MODWT adalah dapat mengeliminasi reduksi data menjadi setengahnya (*down-sampling*) sehingga dalam setiap level akan terdapat koefisien *wavelet* dan skala sebanyak panjang data [9]. Misalkan data runtun waktu dengan panjang N , transformasi MODWT akan memberikan vektor kolom $W_1, W_2, \dots, W_J$ dan V_J masing-masing dengan panjang N .

Filter *wavelet* dan filter *smooth* pada MODWT masing-masing ditulis sebagai berikut [8]:

$$\tilde{h}_{j,l} = \frac{h_{j,l}}{2^{j/2}} \quad (2.52)$$

$$\tilde{g}_{j,l} = \frac{g_{j,l}}{2^{j/2}} \quad (2.53)$$

Dimana j merupakan level dekomposisi dan l adalah panjang dari filter ($l = 0, 1, 2, 3, \dots, L$). l merupakan panjang dari filter yang penentuannya berdasarkan jenis transformasi *wavelet* yang digunakan [8].

Banyaknya koefisien *wavelet* pada setiap level di dalam MODWT selalu sama sehingga lebih sesuai untuk pemodelan data runtun waktu dibandingkan DWT. Prediksi data runtun waktu satu langkah ke depan dimodelkan secara linier berdasarkan koefisien *wavelet* hasil dekomposisi pada langkah-langkah sebelumnya. Misalkan dipunyai sinyal $Z = (Z_t, t = 0, \dots, N - 1)$ maka filter MODWT menjadi:

$$\tilde{W}_{j,t} = \sum_{l=0}^{L_j-1} \tilde{h}_{j,l} Z_t \quad (2.54)$$

$$\tilde{V}_{j,t} = \sum_{l=0}^{L_j-1} \tilde{g}_{j,l} Z_t \quad (2.55)$$

Diketahui $L_j = (2^j - 1)(L - 1) + 1$. Rangkaian dari $\{\tilde{W}_{j,t}\}$ dan $\{\tilde{V}_{j,t}\}$ yang diperoleh berurutan adalah koefisien *wavelet* MODWT dan koefisien *smooth* MODWT. Koefisien $\tilde{h}_{j,l}$ dan $\tilde{g}_{j,l}$ didefinisikan memiliki panjang yang sama dengan banyaknya data atau N . Fungsi $\tilde{W}_{j,t}$ pada persamaan (2.54) dan $\tilde{V}_{j,t}$ pada persamaan (2.55) dinotasikan dalam matriks sebagai berikut [8]:

$$\tilde{W}_j = \tilde{\omega}_j Z \quad (2.56)$$

$$\tilde{V}_j = \tilde{v}_j Z \quad (2.57)$$

$\tilde{W}_j$ adalah koefisien *wavelet* MODWT (detil) disusun berdasarkan persamaan (2.56) dan $\tilde{\omega}_j$ merupakan matriks $N \times N$ yang berisi nilai filter *wavelet* $\{\tilde{h}_{j,l}\}$. Secara umum memiliki struktur sebagai berikut :

$$\tilde{\omega}_j = \begin{bmatrix} \tilde{h}_{j,0} & \tilde{h}_{j,N-1} & \tilde{h}_{j,N-2} & \tilde{h}_{j,N-3} & \cdots & \tilde{h}_{j,3} & \tilde{h}_{j,2} & \tilde{h}_{j,1} \\ \tilde{h}_{j,1} & \tilde{h}_{j,0} & \tilde{h}_{j,N-1} & \tilde{h}_{j,N-2} & \cdots & \tilde{h}_{j,4} & \tilde{h}_{j,3} & \tilde{h}_{j,2} \\ \tilde{h}_{j,2} & \tilde{h}_{j,1} & \tilde{h}_{j,0} & \tilde{h}_{j,N-1} & \cdots & \tilde{h}_{j,5} & \tilde{h}_{j,4} & \tilde{h}_{j,3} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ \tilde{h}_{j,N-2} & \tilde{h}_{j,N-3} & \tilde{h}_{j,N-4} & \cdots & \cdots & \tilde{h}_{j,1} & \tilde{h}_{j,0} & \tilde{h}_{j,N-1} \\ \tilde{h}_{j,N-1} & \tilde{h}_{j,N-2} & \tilde{h}_{j,N-3} & \tilde{h}_{j,N-4} & \cdots & \tilde{h}_{j,2} & \tilde{h}_{j,1} & \tilde{h}_{j,0} \end{bmatrix} \quad (2.58)$$

$\tilde{V}_j$ yang merupakan koefisien *smooth* MODWT (*smooth*) disusun berdasarkan persamaan (2.57) dan $\tilde{v}_j$ merupakan matriks $N \times N$ yang berisi nilai filter *smooth*, dimana strukturnya sama dengan $\tilde{\omega}_j$ namun $\tilde{h}_{j,l}$ diganti $\tilde{g}_{j,l}$ dapat dilihat pada matriks dibawah ini:

$$\tilde{v}_j = \begin{bmatrix} \tilde{g}_{j,0} & \tilde{g}_{j,N-1} & \tilde{g}_{j,N-2} & \tilde{g}_{j,N-3} & \cdots & \tilde{g}_{j,3} & \tilde{g}_{j,2} & \tilde{g}_{j,1} \\ \tilde{g}_{j,1} & \tilde{g}_{j,0} & \tilde{g}_{j,N-1} & \tilde{g}_{j,N-2} & \cdots & \tilde{g}_{j,4} & \tilde{g}_{j,3} & \tilde{g}_{j,2} \\ \tilde{g}_{j,2} & \tilde{g}_{j,1} & \tilde{g}_{j,0} & \tilde{g}_{j,N-1} & \cdots & \tilde{g}_{j,5} & \tilde{g}_{j,4} & \tilde{g}_{j,3} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ \tilde{g}_{j,N-2} & \tilde{g}_{j,N-3} & \tilde{g}_{j,N-4} & \cdots & \cdots & \tilde{g}_{j,1} & \tilde{g}_{j,0} & \tilde{g}_{j,N-1} \\ \tilde{g}_{j,N-1} & \tilde{g}_{j,N-2} & \tilde{g}_{j,N-3} & \tilde{g}_{j,N-4} & \cdots & \tilde{g}_{j,2} & \tilde{g}_{j,1} & \tilde{g}_{j,0} \end{bmatrix} \quad (2.59)$$

Kedua persamaan tersebut menjadi dasar algoritma piramida untuk MODWT. Kemudian apabila disubstitusikan dalam bentuk data runtun waktu, model tersebut digabungkan kembali menjadi sebagai berikut:

$$\begin{aligned} Z &= \sum_{l=0}^{L-1} \tilde{h}_{j,l} \tilde{W}_j + \sum_{l=0}^{L-1} \tilde{g}_{j,l} \tilde{V}_j \\ Z &= \sum_{j=1}^J \tilde{\omega}_j^T \tilde{W}_j + \tilde{v}_j^T \tilde{V}_j \\ Z &= \sum_{j=1}^J \tilde{D}_j + \tilde{S}_j \end{aligned} \quad (2.60)$$

Berdasarkan analisis multi resolusi (mra) maka sinyal wavelet ($\tilde{D}_j$) dan *smooth* MODWT ($\tilde{S}_j$) pada level ke- j adalah sebagai berikut :


$$\tilde{D}_j = \tilde{\omega}_j^T \tilde{W}_j \quad (2.61)$$

$$\tilde{S}_j = \tilde{v}_j^T \tilde{V}_j \quad (2.62)$$

Adapun algoritma piramida level pertama maka persamaan diatas menghasilkan koefisien *wavelet* dan koefisien *smooth* level $\tilde{W}_1$ dan $\tilde{V}_1$ sehinga diperoleh persamaan berikut:

$$\begin{aligned} Z_1 &= \sum_{l=0}^{L-1} \tilde{h}_{j,l} \tilde{W}_j + \sum_{l=0}^{L-1} \tilde{g}_{j,l} \tilde{V}_j \\ Z_1 &= \sum_{l=0}^{L-1} \tilde{h}_{1,l} \tilde{W}_1 + \sum_{l=0}^{L-1} \tilde{g}_{1,l} \tilde{V}_1 \\ Z_1 &= \sum_{l=0}^{N-1} \tilde{h}_{1,l} \tilde{W}_1 + \sum_{l=0}^{N-1} \tilde{g}_{1,l} \tilde{V}_1 \\ Z_1 &= \tilde{\omega}_1^T \tilde{W}_1 + \tilde{v}_1^T \tilde{V}_1 \\ Z_1 &= \tilde{\mathcal{D}}_1 + \tilde{\mathcal{S}}_1 \end{aligned} \quad (2.63)$$

Flowchart dibawah ini menggambarkan algoritma piramida MODWT :



Gambar 2.5 Flowchart Algoritma Piramida MODWT

2.7.3 MODWT-ARIMA

MODWT-ARIMA adalah pengabungan antara model MODWT dan model ARIMA. Model sinyal MODWT apabila dimodelkan dengan ARIMA dapat dilihat pada persamaan koefisien *wavelet* dan koefisien skala sebagai berikut:

$$\tilde{D}_{j,t} = [\phi_j(B) - 1]\tilde{D}_{j,t} + \theta_j(B)\varepsilon_t \quad (2.64)$$

$$\tilde{S}_{j,t} = [\phi(B) - 1]\tilde{S}_{j,t} + \theta(B)\varepsilon_t \quad (2.65)$$

Berdasarkan analisis multi resolusi (mra) maka sinyal *wavelet* ($\tilde{D}_{j,t}$) dan *smooth* MODWT ($\tilde{S}_{j,t}$) pada level ke- j maka diperoleh model sesuai persamaan (2.63) diatas dalam data runtun waktu ditulis menjadi sebagai berikut [8]:

$$Y_t = \sum_{j=1}^J \tilde{D}_{j,t} + \tilde{S}_{j,t} \quad (2.66)$$

Dimana:

Y_t : Dekomposisi sinyal MODWT pada waktu ke- t

$\tilde{D}_{j,t}$: Sinyal *wavelet* pada waktu ke- t level ke- j

$\tilde{S}_{j,t}$: Sinyal *smooth* pada waktu ke- t level ke- j

Dengan mensubstitusikan persamaan (2.64) dan (2.65) pada persamaan (2.66) maka diperoleh prediksi model MODWT-ARIMA sebagai berikut:

$$Y_t = ([\phi_1(B) - 1]\tilde{D}_{1,t} + \theta_1(B)\varepsilon_t + \dots + [\phi_j(B) - 1]\tilde{D}_{j,t} + \theta_j(B)\varepsilon_t) + [\phi(B) - 1]\tilde{S}_{j,t} + \theta(B)\varepsilon_t \quad (2.67)$$

Dengan $t = 1, 2, 3, \dots, N$. Berdasarkan persamaan (2.67) dengan $\tilde{D}_j = \{\tilde{D}_{j,t}, t = 1, 2, 3, \dots, N\}$ dan $j = 1, 2, 3, \dots, J$ menunjukkan *maximal overlap* yaitu seri lokal dari Y_t yang merupakan karakteristik dari dinamika cepat terutama untuk level rendah, kemudian $\tilde{S}_j = \{\tilde{S}_{j,t}, t = 1, 2, 3, \dots, N\}$ memiliki kecenderungan pada seri yang ditandai dengan dinamika lambat (*smooth* ke- j).

2.8 Kriteria Pemilihan Model Terbaik

Dalam pemilihan model terbaik dilakukan guna memeriksa ketepatan suatu model runtun waktu (*time series*). Pemilihan model dilakukan dengan menggunakan *Akaike Information Criterion* (AIC) dan *Schwarz Information Criterion* (SIC). Kriteria AIC memberikan timbangan yang lebih besar daripada R^2 . Menurut kriteria ini model yang baik jika nilai AIC paling kecil. Adapun formulasinya adalah sebagai berikut [36]:

$$AIC = e^{2k/n} \frac{\sum e_i^2}{n} = e^{2k/n} \frac{SSE}{n} \quad (2.68)$$

$$SIC = e^{k/n} \frac{\sum e_i^2}{n} = e^{k/n} \frac{SSE}{n} \quad (2.69)$$

dimana :

e : residual (*error*)

SSE : *Sum Square Error* (jumlah *error* kuadrat)

k : jumlah variabel parameter estimasi.

n : jumlah observasi (sampel)

Bila membandingkan dua regresi atau lebih maka model yang mempunyai nilai AIC terkecil merupakan model yang terbaik [4]. Kriteria SIC mempertimbangkan yang lebih besar daripada AIC. Sebagaimana kriteria AIC, SIC yang rendah menunjukkan model yang lebih baik. Karena SIC memberi timbangan yang lebih besar, maka jika ada kontradiksi antara nilai AIC dan SIC maka yang digunakan adalah kriteria dari SIC.

2.9 Peramalan

Peramalan pada dasarnya merupakan proses menyusun informasi tentang kejadian masa lampau yang berurutan untuk menduga kejadian di masa depan [37]. Peramalan bertujuan mendapatkan ramalan yang dapat meminimumkan kesalahan meramal yang dapat diukur dengan *Mean Absolute Percent Error* (MAPE) [32]. Peramalan pada umumnya digunakan untuk memprediksi sesuatu yang kemungkinan besar akan terjadi misalnya kondisi permintaan, banyaknya curah hujan, kondisi ekonomi, dan lain-lain. Atas dasar logika, langkah dalam metode

peramalan secara umum adalah mengumpulkan data, menyeleksi dan memilih data, memilih model peramalan, menggunakan model terpilih untuk melakukan peramalan, evaluasi hasil akhir. Berdasarkan sifatnya, peramalan dibedakan menjadi dua yaitu:

2.9.1 Peramalan Kualitatif

Peramalan yang didasarkan atas data kualitatif pada masa lalu. Hasil peramalan kualitatif didasarkan pada pengamatan kejadian-kejadian dimasa sebelumnya digabung dengan pemikiran dari penyusunnya.

2.9.2 Peramalan Kuantitatif

Peramalan yang didasarkan atas data kuantitatif masa lalu yang diperoleh dari pengamatan nilai-nilai sebelumnya. Hasil peramalan yang dibuat tergantung pada metode yang digunakan, menggunakan metode yang berbeda akan diperoleh hasil peramalan yang berbeda. Tujuan yang paling penting pada analisis *time series* adalah untuk meramalkan nilai masa depan [38]. Elvitra [39] menjelaskan cara peramalan dengan menggunakan model *MA*, misalkan S_t merupakan himpunan *time series* yang lalu $(Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots)$, maka:

$$\begin{aligned} Y_t'' &= Y_t' - Y_{t-1}' \\ &= Y_t - Y_{t-1} - Y_{t-1} + Y_{t-2} \\ &= Y_t - 2Y_{t-1} + Y_{t-2} \end{aligned}$$

Kemudian Y_t'' dapat diperoleh dari persamaan berikut:

$$\Delta Y_t'' = Y_t'' - Y_{t-1}'' \quad (2.70)$$

Jika semua tahap telah dilakukan dan diperoleh model, maka model ini selanjutnya dapat digunakan untuk melakukan peramalan untuk data periode selanjutnya.

2.10 Ukuran Akurasi Pengukuran

Meramal volatilitas Indeks Harga Saham Gabungan dengan menggunakan bantuan *EViews 10*. Model terbaik untuk evaluasi kesalahan peramalan yaitu dengan melihat model-model notasi peramalan. Beberapa metode lebih ditentukan untuk meringkas kesalahan (*error*) yang dihasilkan oleh fakta (keterangan) pada teknik peramalan. Sebagian besar dari pengukuran ini melibatkan rata-rata

beberapa fungsi dari perbedaan antara nilai *actual* dan nilai peramalannya. Perbedaan antara nilai observasi dan nilai ramalan ini sering dimaksud sebagai residual. Persamaan di bawah ini digunakan untuk menghitung *error* atau sisa untuk tiap periode peramalan [36]:

$$e_t = Y_t - \hat{Y}_t \quad (2.71)$$

Dimana :

e_t : *error* ramalan pada periode waktu t .

Y_t : nilai *actual* pada periode waktu t .

$\hat{Y}_t$: nilai ramalan untuk periode waktu t .

2.10.1 The Mean Squared Error (MSE)

Suatu teknik yang menghasilkan kesalahan moderat mungkin lebih baik untuk salah satu yang memiliki kesalahan kecil tapi kadang-kadang menghasilkan sesuatu yang sangat besar. Berikut ini rumus untuk menghitung MSE [36]:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (2.72)$$

dengan Y_t merupakan nilai *actual* pada periode waktu t dan $\hat{Y}_t$ adalah nilai ramalan untuk periode waktu t . Ada kalanya persamaan ini sangat berguna untuk menghitung kesalahan-kesalahan peramalan dalam bentuk presentase daripada jumlah.

2.10.2 The Mean Absolute Percentage Error (MAPE)

Nilai MAPE dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian, meratarata kesalahan persentase absolut tersebut. Pendekatan ini berguna ketika ukuran atau besar variabel ramalan itu penting dalam mengevaluasi ketepatan ramalan. MAPE mengindikasikan seberapa besar kesalahan dalam meramal yang dibandingkan dengan nilai nyata pada deret. Metode MAPE digunakan jika nilai Y_t besar. MAPE juga dapat digunakan untuk membandingkan ketepatan dari teknik yang sama atau berbeda dalam dua deret yang sangat berbeda dan mengukur ketepatan nilai dugaan model yang dinyatakan dalam bentuk rata-rata persentase absolut kesalahan. MAPE dapat dihitung dengan rumus sebagai berikut [36]:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \quad (2.73)$$

dengan Y_t merupakan nilai *actual* pada periode waktu t dan $\hat{Y}_t$ adalah nilai ramalan untuk periode waktu t .

2.11 Matlab

Matlab (MATrix LABoratory) merupakan perangkat lunak (*software*) yang digunakan dalam analisis komputasi numerik sebagai bahasa pemrograman matematika yang tinggi pada sebuah program analisis serta didasari oleh sifat dan bentuk matriks. Matlab adalah suatu program yang kerap dipakai untuk menyelesaikan berbagai problematika dalam matematika seperti membuat simulasi fungsi sampai membuat model matematika. Matlab ini sangat membantu dalam mempermudah pekerjaan bagi para penelitian, desain sistem dan pengembangan sistem. Salah satu kelebihan Matlab yaitu kemampuan membuat grafik dengan visualisasi yang terbaik. Matematika, statistika serta komputasi merupakan beberapa disiplin ilmu yang menggunakan *software* Matlab. *Software* Matlab yang digunakan dalam penelitian ini yaitu Matlab R2013a.

2.12 EViews

Eviews merupakan perangkat lunak untuk melakukan analisis statistik dan ekonometriks. *Software* ini memiliki kemampuan mengolah berbagai tipe data seperti data runtun waktu, *cross section* dan panel data. Meskipun *EViews* mampu mengolah berbagai tipe data, *software* ini dianggap memiliki kemampuan lebih dalam hal *processing* data runtun waktu karena banyaknya tipe analisis yang dapat digunakan. Selain analisis standar seperti OSL, TSLS, ARMA, GMM, VAR, VECM dan *Kalman Filtering*, *EViews* juga biasa digunakan untuk untuk membangun model. *Software EViews* yang digunakan dalam penelitian ini yaitu *EViews* 10.