

BAB I

PENDAHULUAN

1.1 Latar Belakang

Setiap negara yang merdeka bercita-cita untuk hidup sejahtera. Perekonomian adalah salah satu faktor untuk mencapai kesejahteraan masyarakat. Keberhasilan suatu negara dalam meningkatkan kesejahteraan masyarakatnya dapat diukur melalui keberhasilan pencapaian atas tingkat pertumbuhan ekonomi yang ditunjukkan oleh kestabilan dan peningkatan pada tingkat pertumbuhan perekonomian dari tahun ke tahun. Tingkat pertumbuhan ekonomi juga berguna bagi pemerintah untuk mengevaluasi ketepatan kebijakan yang telah diambil.

Negara berkembang seperti Indonesia memiliki struktur perekonomian yang cenderung masih sangat rentan dengan adanya guncangan pada kestabilan kegiatan perekonomian. Salah satu guncangan tersebut adalah inflasi. Inflasi adalah suatu proses naiknya harga-harga yang berpengaruh dalam suatu perekonomian. Inflasi juga merupakan proses turunnya nilai mata uang secara terus menerus. Nilai inflasi juga dapat digunakan sebagai indikator kestabilan ekonomi. Menurut Thomas Arifin[2], inflasi yang stabil merupakan persyaratan pertumbuhan ekonomi yang akan memberikan keuntungan terhadap kesejahteraan masyarakat.

Inflasi dapat dipengaruhi oleh beberapa hal, diantaranya yaitu nilai

tukar mata uang. Nilai tukar mata uang atau kurs merupakan perbandingan nilai mata uang suatu negara terhadap nilai mata uang negara lainnya. Kurs rupiah terhadap dolar Amerika Serikat memainkan peran sentral dalam perekonomian internasional. Melemahnya nilai tukar rupiah terhadap dolar Amerika Serikat memiliki pengaruh yang buruk terhadap perekonomian negara.

Inflasi secara umum juga dapat terjadi karena banyaknya jumlah uang beredar melebihi jumlah yang dibutuhkan. Jumlah uang beredar merupakan jumlah uang yang ada dan dapat digunakan untuk melakukan berbagai macam transaksi oleh masyarakat dalam perekonomian.

Tingkat inflasi, kurs mata uang dan jumlah uang beredar di Indonesia memiliki pengaruh yang cukup besar bagi peringkatan perekonomian negara. Peran pemerintah dalam melakukan perencanaan, pengambilan serta pengevaluasian suatu kebijakan dalam bidang ekonomi yang berpengaruh pada hal-hal tersebut sangat diperlukan. Oleh karena itu, diperlukan adanya peramalan terhadap tingkat inflasi, nilai tukar mata uang dan jumlah uang beredar.

Tingkat inflasi, nilai tukar mata uang dan jumlah uang beredar merupakan data runtun waktu (*time series*). Data runtun waktu adalah sekumpulan data hasil observasi secara terurut dari waktu ke waktu, sehingga untuk meramalkan tingkat inflasi, nilai tukar mata uang dan jumlah uang beredar dapat menggunakan analisis data runtun waktu. Analisis data runtun waktu yaitu suatu metode analisis pola untuk melihat hubungan antara variabel yang akan diramalkan terhadap waktu. Analisis data runtun waktu bertujuan untuk memperoleh pola data runtun waktu dengan digunakan data masa lalu

yang akan digunakan untuk memprediksi suatu keadaan pada waktu yang akan datang. Hasil analisis dapat disajikan dengan bentuk suatu model.

Vector Autoregressive (VAR) merupakan salah satu metode analisis data runtun waktu. Pada model VAR, suatu variabel selain dipengaruhi oleh nilai variabel tersebut pada waktu lampau juga dipengaruhi oleh nilai semua variabel yang terdapat pada model dimasa lampau. Dengan kata lain model VAR berbentuk hubungan antara variabel terikat Y dengan variabel bebas yang merupakan nilai Y dan X pada waktu sebelumnya. Tingkat inflasi, nilai tukar mata uang dan jumlah uang beredar memiliki keterkaitan satu sama lain, sehingga pemodelan yang cocok untuk ketiga variabel tersebut adalah pemodelan VAR.

Berdasarkan penjelasan di atas, penelitian ini bermaksud untuk memodelkan hubungan nilai tukar rupiah dengan dolar Amerika Serikat, jumlah uang beredar dan tingkat inflasi menggunakan pemodelan *vector autoregressive*. Oleh karena itu, peneliti memilih judul *Vector Autoregressive* untuk Memodelkan Hubungan Nilai Tukar Rupiah terhadap Dolar Amerika Serikat, Jumlah Uang Beredar dan Tingkat Inflasi.

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang di atas, maka permasalahan yang akan dibahas pada penelitian ini adalah:

1. Bagaimana bentuk model VAR dari hubungan nilai tukar rupiah ter-

hadap dolar Amerika Serikat, jumlah uang beredar dan tingkat inflasi?

2. Bagaimana dampak dari perubahan variabel nilai tukar rupiah terhadap dolar Amerika Serikat, jumlah uang beredar dan tingkat inflasi pada masing-masing variabel?

1.3 Tujuan Penelitian

Sesuai dengan permasalahan di atas, maka tujuan dari penelitian ini adalah:

1. Membentuk model VAR dari hubungan nilai tukar rupiah terhadap dolar Amerika Serikat, jumlah uang beredar dan tingkat inflasi.
2. Mengevaluasi dampak dari perubahan variabel nilai tukar rupiah terhadap dolar Amerika Serikat, jumlah uang beredar dan tingkat inflasi pada masing-masing variabel.


1.4 Sistematika Penulisan

Penulisan tugas akhir ini akan dibagi menjadi lima bab, yaitu:

1. BAB I Pendahuluan yang membahas mengenai latar belakang, rumusan masalah, tujuan penelitian dan sistematika penulisan.
2. BAB II Landasan Teori yang membahas mengenai teori-teori sebagai dasar acuan yang digunakan dalam pembahasan dan mendukung masalah yang dibahas, diantaranya yaitu stasioneritas, kointegrasi, signifikansi

parameter, proses *white noise*, kestabilan model, kausalitas *granger*, *impulse response functions*, dan *varians decomposition*.

3. BAB III Metode Penelitian. Pada bab ini akan menjelaskan tentang langkah-langkah dalam menyelesaikan masalah pada rumusan masalah.
4. BAB IV Pembahasan yang akan memaparkan pemodelan *vector autoregressive* untuk meramalkan nilai tukar rupiah dengan dolar, jumlah uang beredar dan tingkat inflasi.
5. BAB V Penutup yang berisi kesimpulan dan saran berdasarkan hasil pembahasan.



BAB II

LANDASAN TEORI

Pada bab ini akan dibahas konsep-konsep dasar dan teori-teori yang digunakan untuk memodelkan *vector autoregressive*, antara lain adalah istilah dalam bidang keuangan, *time series*, konsep pemodelan dengan menggunakan *vector autoregressive*.

2.1 Istilah-istilah dalam Keuangan

Pada bagian ini akan dijelaskan beberapa istilah keuangan yang akan digunakan dalam pemodelan terhadap peramalan nilai tukar mata uang, jumlah uang beredar dan tingkat inflasi.

2.1.1 Nilai Tukar (Kurs) Mata Uang Rupiah terhadap Dolar Amerika Serikat

Kurs merupakan nilai sebuah mata uang suatu negara yang dinyatakan dalam mata uang negara lain. Prospek dan fundamental perekonomian suatu negara dapat dicerminkan dari kurs. Kurs merupakan salah satu unsur terpenting dalam perekonomian mengingat pengaruhnya yang demikian besar bagi unsur-unsur makro ekonomi yang lainnya. Kondisi ekonomi yang relatif baik atau stabil dapat ditunjukkan dengan pertumbuhan nilai mata uang. Kenaikan nilai tukar (kurs) mata uang rupiah disebut dengan apresiasi atas mata

uang atau dengan kata lain harga mata uang asing lebih murah, sedangkan penurunan nilai tukar (kurs) mata uang rupiah disebut depresiasi atas mata uang atau dengan kata lain harga mata uang asing lebih mahal[11].

Nilai tukar (kurs) mata uang rupiah terhadap dolar Amerika Serikat memainkan peran sentral dalam perdagangan internasional. Nilai tukar rupiah terhadap dolar Amerika Serikat memberikan pengaruh pada perekonomian nasional tergantung keadaan apresiasi atau depresiasi nilai tukar tersebut[11].

2.1.2 Jumlah Uang Beredar

Uang merupakan suatu benda yang dapat ditukarkan dengan benda lainnya. Menurut Glyn Davies, fungsi uang terbagi menjadi dua, yaitu[14]:

1. Fungsi khusus. Fungsi khusus uang yaitu sebagai alat pembayaran dan sebagai alat ukuran untuk menilai sesuatu.
2. Fungsi umum. Fungsi umum uang yaitu sebagai aset likuid (aset yang dapat dikonversi menjadi uang tunai dalam waktu yang singkat dan nilai yang wajar), faktor pembentukan harga pasar, faktor penyebab dalam perekonomian dan faktor pengendali dalam sistem ekonomi.

Berdasarkan jenis yang beredar, uang dikelompokkan menjadi dua yaitu uang kartal dan uang giral. Uang kartal merupakan alat pembayaran yang sah yang digunakan pada proses transaksi jual beli oleh masyarakat. Namun uang kartal milik pemerintah (Bank Indonesia) yang disimpan di bank-bank umum tidak termasuk dalam uang kartal. Uang yang dimiliki oleh masyarakat dalam

bentuk simpanan dan dapat ditarik sesuai kebutuhan disebut sebagai uang giral. Saldo simpanan bank umum yang disimpan di bank lain tidak termasuk uang giral[1].

Jumlah uang beredar merupakan jumlah uang yang ada dan dapat digunakan untuk melakukan berbagai macam transaksi oleh masyarakat dalam perekonomian. Jumlah uang beredar didefinisikan dalam dua pengertian yaitu[10]:

1. Uang beredar dalam arti sempit (M_1)

Jumlah uang kartal dan uang giral didefinisikan sebagai uang beredar dalam arti sempit atau dapat ditulis

$$M_1 = C + DD \quad (2.1.1)$$

dimana C adalah jumlah uang kartal dan DD adalah jumlah uang giral.

2. Uang beredar dalam arti luas (M_2)

Jumlah uang beredar meliputi M_1 , uang kuasi (simpanan berjangka dalam rupiah dan valas, giro dalam valuta asing dan tabungan) dan surat berharga yang dikeluarkan oleh sistem moneter disebut sebagai uang beredar dalam arti luas

$$M_2 = M_1 + TD + SD \quad (2.1.2)$$

dimana TD adalah *time deposits* (deposit berjangka), SD adalah *savings deposits* (saldo tabungan).

2.1.3 Tingkat Inflasi

Inflasi merupakan suatu proses peningkatan harga-harga. Inflasi dapat disebabkan oleh berbagai faktor yang memberikan pengaruh dalam suatu perekonomian. Inflasi dikatakan terjadi jika kondisi-kondisi berikut ini dipenuhi[7]:

1. Bila kenaikan harga barang meluas dan membawa dampak terhadap sebagian besar dari harga barang-barang lain. Kenaikan harga dari satu atau dari dua macam barang saja tidak dapat dikatakan sebagai inflasi.
2. Kenaikan harga barang-barang yang bersifat umum dan terjadi secara terus-menerus. Kenaikan harga-harga yang hanya bersifat sementara misalnya, musiman, menjelang hari raya, bencana, dan sebagainya, tidak disebut inflasi.

Tingkat inflasi dapat diukur menggunakan Indeks Harga Konsumen (IHK) dan dirumuskan sebagai berikut[9]:

$$LI_t = \frac{IHK_t - IHK_{t-1}}{IHK_{t-1}} \times 100\% \quad (2.1.3)$$

dengan:

LI_t = Tingkat inflasi pada waktu ke- t ,

IHK_t = Indeks Harga Konsumen pada waktu ke- t ,

IHK_{t-1} = Indeks Harga Konsumen pada waktu ke- $(t - 1)$.

2.2 Peramalan (*Forecasting*)

Peramalan merupakan suatu proses penyusunan informasi mengenai kejadian masa lalu untuk menduga kejadian di masa depan. Peramalan umumnya digunakan untuk memprediksi sesuatu yang berkemungkinan besar terjadi.

Dalam pengambilan keputusan, peramalan merupakan salah satu unsur penting. Kefektifan suatu keputusan seringkali dipengaruhi oleh beberapa faktor yang tidak dapat dilihat pada waktu keputusan itu diambil [13].

Langkah-langkah dalam melakukan suatu peramalan secara umum adalah mengumpulkan data, menyeleksi dan memilih data, memilih model peramalan, menggunakan model terpilih untuk melakukan peramalan, dan evaluasi hasil akhir.

2.3 Data dan Analisis Runtun Waktu (*Time Series*)


Himpunan hasil observasi terhadap suatu variabel yang diambil secara beruntun atau teratur berdasarkan interval waktu yang tetap disebut data runtun waktu (*time series*). Menurut banyaknya variabel yang diamati, data runtun waktu terbagi menjadi dua yakni data runtun waktu univariat dan data runtun waktu multivariat[15].

Analisis sekumpulan data yang menjelaskan dan mengukur perubahan serta perkembangan data selama satu periode waktu yang lampau disebut dengan analisis data runtun waktu. Analisis untuk data runtun waktu dengan satu variabel saja disebut dengan analisis runtun waktu univariat, sedangkan

analisis untuk data runtun waktu multivariat disebut dengan analisis runtun waktu multivariat [15].


Analisis runtun waktu digunakan untuk memperoleh pola data runtun waktu pada masa lampau yang akan digunakan untuk memprediksi suatu nilai variabel atau kondisi pada masa yang akan datang. Terdapat empat bentuk tipe pola data dalam runtun waktu sebagai berikut:

1. Pola *horizontal* atau stasioner yaitu terjadi ketika data observasi berubah-ubah atau berfluktuasi di sekitar tingkatan atau rata-rata yang konstan.




Gambar 2.3.1: Ilustrasi pola *horizontal* data runtun waktu

2. Pola *trend* yaitu ketika data observasi mengalami kenaikan atau penurunan selama periode jangka panjang. Suatu data observasi yang memiliki pola *trend* disebut data nonstasioner.




Gambar 2.3.2: Ilustrasi pola *trend* data runtun waktu

3. Pola Musiman (*seasonal*) yaitu ketika observasi dipengaruhi oleh faktor musiman atau ketika terdapat pola perubahan yang berulang secara otomatis dalam kurun waktu satu tahun, seperti triwulan, kuartalan, bulanan, mingguan, atau harian. Pola musiman berguna dalam meramalkan penjualan jangka pendek.



Gambar 2.3.3: Ilustrasi pola *seasonal* data runtun waktu

4. Pola siklik yaitu pola yang terjadi jika adanya fluktuasi bergelombang data yang terjadi di sekitar garis trend. Pola siklik ini sangat berguna dalam peramalan jangka menengah.



Gambar 2.3.4: Ilustrasi pola siklik data runtun waktu

Ada dua asumsi yang harus di perhatikan dari data runtun waktu agar dapat dilakukan analisis runtun waktu, kedua asusmsi tersebut adalah:

1. Stasioneritas,
2. Normalitas dan independensi error.

2.4 Stasioneritas Data

Stasioneritas data adalah salah satu topik yang sangat penting dalam analisis runtun waktu. Tidak stasionernya data akan mengakibatkan kurang baiknya model yang diestimasi. Sekumpulan data dinyatakan stasioner jika

nilai rata-rata dan varian dari data runtun waktu tersebut tidak mengalami perubahan secara sistematis sepanjang waktu[5]. Sebagian ahli menyatakan kondisi ini sebagai kondisi dengan rata-rata dan variannya konstan.

Jadi terdapat dua perilaku stasioneritas data, yaitu[5]:

1. Stasioneritas dalam *mean*. Data bersifat stasioner dalam *mean* terjadi ketika data tersebut berubah-ubah di sekitar nilai tengah (rata-rata) yang konstan sepanjang/selama periode observasi. Jika data tidak stasioner, dapat dilihat sampai dimana data tersebut stasioner. Jika data runtun waktu tidak stasioner dalam *mean*, maka langkah yang dilakukan adalah dengan melakukan pembedaan (*differencing*) tahap pertama dan kedua terhadap data asli.
2. Stasioneritas dalam varian. Data bersifat stasioner pada variannya yaitu apabila data mengalami perubahan dengan varian yang konstan sepanjang periode penelitian. Langkah untuk menghilangkan non-stasioneritas dalam varian adalah dengan mentransformasi data asli.


Pada penerapannya, kestasioneran dalam mean sering kali tidak memerlukan kestasioneran dalam varians. Namun, proses tidak stasioner dalam mean juga akan menyebabkan tidak stasioner dalam variannya. Suatu data dikatakan stasioner jika memenuhi syarat berikut[8]:

(a) $E(Y_t) = \mu$, yaitu rata-rata dari Y konstan,

(b) $Var(Y_t) = E(Y_t - \mu_t)^2 = \sigma^2$, varians Y konstan,


(c) $Cov(Y_t, Y_{t+k}) = E[(Y_t - \mu_t)][(Y_{t+k} - \mu_{t+k})] = \gamma_k$, kovarians antara dua data runtun waktu hanya tergantung pada selang waktu k antara dua periode waktu tersebut. Selang waktu antara Y_t dan Y_{t+k} ini disebut dengan *lag*.

Stasioneritas data dapat dilihat secara langsung melalui analisis grafis yaitu dengan membuat plot dari runtun data yang dimiliki. Dari pergerakan data tersebut dapat diketahui apakah data stasioner atau tidak[12].




Gambar 2.4.5: Ilustrasi plot data stasioner dalam mean

Gambar 2.4.5 menunjukkan data stasioner dalam *mean* karena data berfluktuasi disekitar nilai rata-ratanya.




Gambar 2.4.6: Ilustrasi plot data tidak stasioner dalam mean

Gambar 2.4.6 menunjukkan data tidak stasioner dalam *mean* dikarenakan data tersebut tidak berfluktuasi pada nilai rata-ratanya.



Gambar 2.4.7: Ilustrasi plot data stasioner dalam varian

Gambar 2.4.7 merupakan plot data stasioner dalam varian, hal ini dikarenakan ragam dari data tidak membentuk pola tertentu (konstan).



Gambar 2.4.8: Ilustrasi plot data tidak stasioner dalam varian

Gambar 2.4.8 merupakan plot data non-stasioner dalam varian dikarenakan ragam dari data membentuk pola tertentu (ragam data membesar).

2.4.1 Akar Unit

Akar unit merupakan istilah lain dari proses *random walk*. *Random walk* merupakan suatu kondisi dimana ekspektasi kedepan merupakan hasil dari ekspektasi sekarang ditambah *error*, sehingga dapat dituliskan sebagai berikut:

$$Y_t = Y_{t-1} + e_t \quad (2.4.1)$$

dimana $E(e_t) = 0$ dan $E(e_t e_s) = 0$.

Peramalan satu periode kedepan menggunakan proses *random walk* diberikan sebagai berikut:

$$\begin{aligned}\hat{Y}_{t+1} &= E(Y_{t+1}|Y_t, \dots, Y_1) = E(Y_t + e_{t+1}) \\ &= Y_t + E(e_{t+1}) = Y_t\end{aligned}$$

Peramalan untuk dua periode kedepan diberikan sebagai berikut:

$$\begin{aligned}\hat{Y}_{t+2} &= E(Y_{t+2}|Y_t, \dots, Y_1) = E(Y_{t+1} + e_{t+2}) \\ &= E(Y_t + e_{t+1} + e_{t+2}) = Y_t\end{aligned}$$

Secara umum peramalan untuk periode ke i akan sama dengan Y_t . Namun, varian *error* cenderung makin besar. Untuk satu periode peramalan diperoleh sebagai berikut:

$$\begin{aligned}e_1 &= Y_{t+1} - \hat{Y}_{t+1} = Y_t + e_{t+1} - Y_t = e_{t+1} \\ E([e_1]^2) &= E(e_{t+1}^2) = \sigma_e^2\end{aligned}$$

Untuk dua periode peramalan diperoleh sebagai berikut:

$$\begin{aligned}e_2 &= Y_{t+2} - \hat{Y}_{t+2} = Y_t + e_{t+1} + e_{t+2} - Y_t = e_{t+1} + e_{t+2} \\ E([e_2]^2) &= E([e_{t+1} + e_{t+2}]^2) \\ &= E(e_{t+1}^2) + E(e_{t+2}^2) + 2E(e_{t+1}e_{t+2}) \\ &= 2\sigma_e^2\end{aligned}$$

2.4.2 Uji *Augmented Dickey-Fuller* (ADF)

Salah satu cara menguji kestasioneritasan dalam *mean* pada data runtun waktu adalah menggunakan uji akar unit (*unit roots test*). Data runtun waktu dikatakan stasioner jika tidak mengandung akar unit. Uji *Augmented Dickey-Fuller* (ADF) adalah metode uji akar unit yang paling terkenal. Pada uji ini akan dilihat apakah terdapat akar unit di dalam model atau tidak[12]. Untuk melihat keberadaan akar unit dalam model dapat digunakan persamaan berikut:

$$\Delta Y_t = \alpha + \delta t + \beta Y_{t-1} + \sum_{i=1}^k \phi_i \Delta Y_{t-1} + e_t \quad (2.4.2)$$

dimana e_t adalah *error* yang *white noise* yaitu error yang memiliki rata-rata dan ragam yang konstan serta saling bebas (tidak berautokorelasi), $\Delta Y_t = Y_t - Y_{t-1}$, $\beta = \alpha - 1$ dan adalah Δ operator *first-difference* (bagian ini akan dibahas pada subbab selanjutnya).

Hipotesis pada uji ADF adalah sebagai berikut[9]:

$H_0 : \beta = 0$ (Y_t memiliki akar unit atau tidak stasioner)

$H_1 : \beta \neq 0$ (Y_t tidak memiliki akar unit atau stasioner)

Statistik uji yang digunakan adalah statistik t dengan

$$t = \frac{\hat{\beta}}{SE(\hat{\beta})} \quad (2.4.3)$$

Kesimpulan diambil berdasarkan kriteria uji bahwa H_0 ditolak jika nilai statistik uji memiliki nilai lebih kecil daripada nilai kritis *McKinnon* (tabel dapat dilihat pada bagian lampiran 4).

2.4.3 Proses Pembeda (*Differencing*)

Proses pembeda merupakan suatu proses yang digunakan untuk membuat data runtun waktu yang tidak stasioner dalam *mean* menjadi data runtun waktu yang stasioner. Proses ini dilakukan dengan cara mengurangi data pada periode bersangkutan dengan data periode sebelumnya. Proses pembeda sangat tepat digambarkan dengan operator *shift* mundur (*backward shif*) sebagai berikut[8]:

$$BY_t = Y_{t-1} \quad (2.4.4)$$

dimana B memiliki pengaruh menggeser data Y_t 1 periode ke belakang. Dua penerapan B untuk Y_t akan menggeser data tersebut 2 periode ke belakang, sebagai berikut:

$$BBY_t = B^2Y_t = Y_{t-2} \quad (2.4.5)$$

Apabila suatu data runtun waktu tidak stasioner, maka data tersebut dapat dibuat lebih mendekati stasioner dengan melakukan pembedaan pertama (*first difference*).

$$\Delta Y_t = Y_t - Y_{t-1} \quad (2.4.6)$$

Dengan menggunakan operator shift mundur, persamaan (2.4.6) dapat ditulis menjadi:

$$\Delta Y_t = Y_t - BY_t = (1 - B)Y_t \quad (2.4.7)$$

dimana $(1-B)$ menyatakan pembedaan pertama.

Sama halnya dengan pembedaan kedua (yaitu pembedaan pertama dari pembedaan pertama sebelumnya), yaitu:

$$\begin{aligned}
 \Delta^2 Y_t &= \Delta Y_t - \Delta Y_{t-1} \\
 &= Y_t - Y_{t-1} - (Y_{t-1} - Y_{t-2}) \\
 &= Y_t - 2Y_{t-1} + Y_{t-2} \\
 &= (1 - 2B + B^2)Y_t \\
 &= (1 - B)^2 Y_t
 \end{aligned}$$

Pembedaan orde kedua diberi notasi $(1 - B)^2$, sedangkan pembedaan orde pertama diberi notasi $(1 - B)$.

Menghitung pembedaan bertujuan untuk mencapai stasioneritas dan secara umum pembedaan orde ke- n yang dilakukan untuk mencapai stasioneritas dapat ditulis sebagai berikut:

$$(1 - B)^n Y_t \quad (2.4.8)$$

2.4.4 Transformasi Data

Ketidakstasioneran data pada variannya dapat dihilangkan dengan melakukan transformasi *Box-Cox* melalui pemilihan dan penetapan nilai λ . Secara umum, transformasi *Box-Cox* yang digunakan dinyatakan sebagai berikut[3]:

$$T(Y_t) = (Y_t)^{(\lambda)} = \begin{cases} \frac{(Y_t)^{(\lambda)} - 1}{\lambda} & ; \lambda \neq 0, \\ \ln(Y_t) & ; \lambda = 0, \end{cases} \quad (2.4.9)$$

Nilai $\lambda = 1$ pada transformasi *Box-Cox* menunjukkan data sudah stasioner pada variannya sedangkan nilai λ lainnya menunjukkan data belum stasioner. Berikut bentuk-bentuk transformasi yang umum berdasarkan nilai λ [15]:

Tabel 2.4.1: Bentuk-bentuk Transformasi

Nilai λ	Bentuk Transformasi
-3	$\frac{1}{Y_t^3}$
-2	$\frac{1}{Y_t^2}$
-1	$\frac{1}{Y_t}$
-0.5	$\frac{1}{\sqrt{Y_t}}$
0	$\ln(Y_t)$
0.5	$\sqrt{Y_t}$
1	Y_t (tidak ditransformasi)
2	Y_t^2
3	Y_t^3

Nilai λ yang dipilih yaitu nilai λ yang dapat meminimalkan nilai $S(\lambda)$ dan dirumuskan sebagai berikut:

$$S(\lambda) = \ln \sum_{t=1}^N (Y_t(\lambda) - \bar{Y}_t(\lambda))^2 - \frac{2}{N}(\lambda - 1) \sum_{t=1}^N \ln Y_t \quad (2.4.10)$$

dengan

$Y_t(\lambda)$: nilai data yang telah ditransformasi,

$\bar{Y}_t(\lambda)$: rata-rata dari Y_t ,

N : banyaknya data.

2.5 Model *Autoregressive*

Model *autoregressive* digunakan untuk mendeskripsikan suatu keadaan dimana nilai sekarang dari suatu deret waktu bergantung pada nilai-nilai sebelumnya. Bentuk umum model *autoregressive* dengan *lag* p (AR(p)) adalah[13]:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t \quad (2.5.1)$$

dengan:

Y_t = nilai variabel Y pada waktu ke t ,

ϕ_i = parameter *autoregressive* ke- i dengan $i=1,2,\dots,p$,

ϵ_t = nilai error (residual) pada saat t , dengan $\epsilon_t \sim N(0, \sigma^2)$.

Dengan menggunakan operator *shift* mundur, persamaan (2.5.1) dapat ditulis menjadi:

$$Y_t = \phi_1 B Y_t + \phi_2 B^2 Y_t + \dots + \phi_p B^p Y_t + \epsilon_t \quad (2.5.2)$$

atau

$$\phi B Y_t = \epsilon_t \quad (2.5.3)$$

dengan $\phi B = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$.

Setelah data runtun waktu terbukti stasioner, langkah selanjutnya adalah mengestimasi parameter model dengan menggunakan metode kuadrat terkecil (*least square method*). Dari n observasi $Y_1, Y_2, \dots, Y_n$ parameter $\phi_1, \phi_2, \dots, \phi_p$ dapat diestimasi dengan meminimumkan jumlah kuadrat residual (*Sum*

Squared Error (SSE))

$$S = \sum_{t=p+1}^n \epsilon_t^2 \quad (2.5.4)$$

$$= \sum_{t=p+1}^n [Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p}]^2 \quad (2.5.5)$$

seperti berikut:

$$\frac{\partial S}{\partial \phi_i} = 0 \quad (2.5.6)$$

sehingga diperoleh estimasi untuk parameter ϕ_i yang dinotasikan dengan $\hat{\phi}_i$

2.6 Model *Vector Autoregressive* (VAR)

Model *vector autoregressive* merupakan pengembangan dari model *Autoregressive* (AR) untuk lebih dari 1 variabel. Pada model VAR semua variabel dianggap sebagai variabel yang nilainya dipengaruhi oleh variabel lain dalam model atau variabel endogen dan saling berhubungan. Bentuk umum model VAR dengan *lag p* (VAR(*p*)) sebagai berikut[15]:

$$Y_t = \phi_0 + \phi_1 X_{1,t-1} + \dots + \phi_p X_{p,t-p} + e_t, t = 1, 2, \dots \quad (2.6.1)$$

dimana :

Y_t = vektor peubah tak bebas ($Y_{1,t}, Y_{2,t}, \dots, Y_{m,t}$) berukuran $m \times 1$,

$X_{i,t-i}$ = vektor peubah tak bebas ($X_{1,t-i}, X_{2,t-i}, \dots, X_{m,t-i}$) berukuran $m \times 1$

untuk setiap $i = 1, 2, \dots, p$,

ϕ_0 = vektor intersep berukuran $m \times 1$,

ϕ_i = matriks koefisien berukuran $m \times m$ untuk setiap $i=1,2,\dots,p$,

e_t = vektor sisaan ($e_{1,t}, e_{2,t}, \dots, e_{m,t}$) berukuran $m \times 1$.

2.7 Uji Kointegrasi

Kointegrasi adalah suatu konsep di dalam ekonometrika yang menunjukkan adanya fenomena keserasian atau keberiringan fluktuasi beberapa data pada jangka waktu tertentu. Uji kointegrasi digunakan melanjutkan analisis data runtun waktu yang non-stasioner. Jika suatu data terjadi kointegrasi, maka pemodelan untuk data tersebut tidak dapat menggunakan model VAR. Sebagai dasarnya kointegrasi adalah bahwa sejumlah data runtun waktu yang dapat menyimpang dari rata-ratanya dalam jangka pendek, namun bergerak bersama-sama[5]. Teknik kointegrasi diperkenalkan oleh Engle dan Granger pada tahun 1987 yang kemudian disempurnakan oleh Johansen dan Juselius pada tahun 1990.

Hipotesis pada pengujian Johansen adalah sebagai berikut[11]:

H_0 : terdapat sebanyak r , dimana $r=0,1,...,k-1$ persamaan kointegrasi (tidak terjadi kointegrasi atau hubungan jangka panjang antar variabel)

H_1 : terdapat k persamaan kointegrasi (terjadi kointegrasi atau hubungan jangka panjang antar variabel)

dengan r menyatakan *rank* dan k menyatakan banyaknya variabel endogen di dalam model VAR. Statistik uji yang digunakan adalah statistik uji *trace* yang dirumuskan sebagai berikut:

$$LR_u(r|k) = -N \sum_{i=r+1}^k \log(1 - \lambda_i) \quad (2.7.1)$$

dimana:

N = ukuran sampel,

λ_t = nilai eigen terbesar ke- i dari matriks Π dimana

$$\Pi = \sum_{i=1}^p (A_i - I) \quad (2.7.2)$$

dengan $A_i, i=1, \dots, p$ adalah matriks koefisien berdimensi $(k \times k)$ dari persamaan *autoregressive* yang telah diperoleh. Kesimpulan diambil dengan kriteria uji H_0 ditolak jika nilai statistik uji *trace* lebih dari nilai kritis *McKinnon-Haug-Michelis*.

2.8 Pemilihan *Lag* p dan Uji *Lag* Optimum

Estimasi VAR sangat peka terhadap panjang *lag* yang digunakan. Penentuan panjangnya *lag* optimal merupakan hal penting dalam pemodelan VAR.[12]. Jika *lag* yang dimasukan terlalu pendek maka dikhawatirkan tidak dapat menjelaskan kedinamisan model secara menyeluruh. Namun, jika *lag* terlalu panjang akan menghasilkan estimasi yang tidak efisien karena berkurangnya *degree of freedom* (terutama model dengan sampel kecil). Oleh karena itu, perlu mengetahui *lag* optimal sebelum melakukan estimasi VAR[6].

Penentuan jumlah *lag* yang optimal dapat ditentukan menggunakan *Akaike Information Criterion* (AIC), *Schwarz Information Criterion* (SC) ataupun *Hannan Quinnon* (HQ). Pada penelitian ini untuk menentukan panjang *lag* optimum digunakan *Akaike Information Criterion* (AIC) dengan bantuan *Software Eviews*.

Penentuan *lag* optimal dengan menggunakan kriteria informasi tersebut diperoleh dengan memilih kriteria yang mempunyai nilai paling kecil atau

tanda bintang paling banyak di antara berbagai *lag* yang diajukan. Model VAR akan diestimasi dengan tingkat *lag* yang berbeda-beda dan selanjutnya nilai terkecil atau tanda bintang paling banyak (pada hasil pengolahan data dengan bantuan *software Eviews*) akan digunakan sebagai nilai *lag* yang optimal. Penentuan jumlah *lag* yang optimal bertujuan menghilangkan masalah autokorelasi dalam model VAR dan diharapkan tidak lagi muncul masalah autokorelasi.

Perhitungan untuk *Akaike Information Criterion* (AIC) adalah sebagai berikut:

$$AIC(p) = \ln \left| \hat{\Sigma}_p \right| + \frac{2k^2p}{N} \quad (2.8.1)$$

dimana

k = banyaknya parameter pada model,

$\hat{\Sigma}_p$ = matriks dugaan varian-kovarian residual,

p = panjang lag,

N = banyak pengamatan.

2.9 Pendugaan Parameter

Persamaan 2.6.1 dapat ditulis sebagai berikut:

$$\underline{y} = \mathbf{X}\underline{\phi} + \underline{e} \quad (2.9.1)$$

Penaksiran *Ordinary Least Square* (OLS) bagi ϕ diperoleh dengan cara meminimumkan jumlah kuadrat sisaan yang dinyatakan sebagai berikut[6]:

$$\sum_{i=1}^n e_i^2 = e_1^2 + e_2^2 + \dots + e_n^2 \quad (2.9.2)$$

$$= \begin{pmatrix} e_1 & e_2 & \dots & e_n \end{pmatrix} \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{pmatrix} \quad (2.9.3)$$

$$= \underline{e}'\underline{e} \quad (2.9.4)$$

dimana $\underline{e}'$ menyatakan *transpose* dari $\underline{e}$. Berdasarkan persamaan 2.9.1 maka persamaan 2.9.2 dapat ditulis sebagai berikut:

$$\sum_{i=1}^n e_i^2 = \underline{e}'\underline{e} = (\underline{y} - \underline{X}\underline{\phi})'(\underline{y} - \underline{X}\underline{\phi}) \quad (2.9.5)$$

$$= \underline{y}'\underline{y} - \underline{\phi}'\underline{X}'\underline{y} - \underline{y}'\underline{X}\underline{\phi} + \underline{\phi}'\underline{X}'\underline{X}\underline{\phi} \quad (2.9.6)$$

dimana digunakan sifat transpose matriks yakni $(\underline{X}\underline{\phi})' = \underline{\phi}'\underline{X}'$ dan karena $\underline{\phi}'\underline{X}'\underline{y}$ merupakan suatu matriks berukuran 1 x 1, maka

$$\underline{\phi}'\underline{X}'\underline{y} = (\underline{\phi}'\underline{X}'\underline{y})' \quad (2.9.7)$$

$$\text{atau } \underline{\phi}'\underline{X}'\underline{y} = \underline{y}'\underline{X}\underline{\phi} \quad (2.9.8)$$

Oleh karena itu, persamaan 2.9.5 dapat ditulis sebagai

$$\sum_{i=1}^n e_i^2 = \underline{y}'\underline{y} - 2\underline{\phi}'\underline{X}'\underline{y} + \underline{\phi}'\underline{X}'\underline{X}\underline{\phi} \quad (2.9.9)$$

Penaksiran OLS pada $\underline{\phi}$ dapat diperoleh dengan meminimumkan $\sum_{i=1}^n e_i^2$.

Hal ini dicapai dengan mendiferensialkan persamaan 2.9.9 terhadap elemen $\underline{\phi}$

dan menyamakan hasil yang diperoleh dengan nol seperti di bawah ini:

$$\frac{\partial(\sum_{i=1}^n e_i^2)}{\partial \underline{\phi}} = \frac{\partial(e'e)}{\partial \underline{\phi}} = -2\mathbf{X}'\underline{y} + 2\mathbf{X}'\mathbf{X}\underline{\phi} \quad (2.9.10)$$

$$\frac{\partial(e'e)}{\partial \underline{\phi}} = 0 \quad (2.9.11)$$

sehingga diperoleh bentuk penduga kuadrat terkecil bagi ϕ sebagai berikut:

$$\Longleftrightarrow -2\mathbf{X}'\underline{y} + 2\mathbf{X}'\mathbf{X}\underline{\phi} = 0 \quad (2.9.12)$$

$$\Longleftrightarrow \mathbf{X}'\mathbf{X}\hat{\underline{\phi}} = \mathbf{X}'\underline{y} \quad (2.9.13)$$

$$\Longleftrightarrow \hat{\underline{\phi}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\underline{y} \quad (2.9.14)$$

2.10 Uji Signifikan Parameter

Uji individual (uji-t) dilakukan untuk menguji pengaruh masing-masing parameter terhadap model. Uji signifikan parameter model pada parameter *autoregressive* menggunakan hipotesis pengujian sebagai berikut [9]:

$H_0 : \phi = 0$ (parameter ϕ tidak signifikan dalam model)

$H_1 : \phi \neq 0$ (parameter ϕ signifikan dalam model) Statistik uji yang digunakan adalah statistik uji t

$$t_{hitung} = \frac{\hat{\phi}}{SE(\hat{\phi})} \quad (2.10.1)$$

Kesimpulan diambil dengan kriteria uji H_0 ditolak jika $|t_{hitung}| > t_{\alpha, \frac{db}{2}}$ dengan derajat bebas $db = n - m$, dimana n adalah banyaknya data dan m adalah banyaknya parameter dalam model.

2.11 Uji *White Noise* Residual

Dalam penelitian kerap muncul istilah *White Noise* untuk menjelaskan bagaimana suatu data berperilaku. Istilah *White Noise* menjelaskan bahwa data memiliki perilaku acak dan stasioner[5]. Uji *White Noise* juga digunakan sebagai menguji kecocokan model VAR yang telah diestimasi[12]. Pengujian ini dilakukan dengan menggunakan statistik uji *Portmanteau*. Pengujian dengan uji *White Noise* menggunakan hipotesis sebagai berikut:

H_0 : terdapat masalah heteroskedastisitas

H_1 : tidak terdapat masalah heteroskedastisitas

Statistik uji dihitung menggunakan statistik uji *Portmanteau* yang dirumuskan sebagai berikut:

$$Q_m = T \sum_{j=1}^m \text{tr}(\hat{C}_j' \hat{C}_0^{-1} \hat{C}_j \hat{C}_j^{-1}) \quad (2.11.1)$$

dengan $\hat{C}_i = \frac{1}{T} \sum_{t=i+1}^T \hat{u}_t \hat{u}_{t-i}'$ Kesimpulan yang diambil adalah dengan kriteria uji H_0 ditolak jika nilai statistik uji lebih besar dari nilai $\chi^2(k^2(m-n^*))$, dengan k adalah jumlah variabel endogen, n^* adalah jumlah koefisien selain konstanta dari model VAR(p) yang diestimasi dan m adalah *lag*.

2.12 Uji Stabilitas

Model VAR terdiri dari variabel yang dipengaruhi oleh variabel itu sendiri pada masa lalu. Dapat dipahami bahwa, jika variabel dipengaruhi oleh masa lalunya sebesar nilai parameter, apakah akan membuat konvergen

menuju keseimbangan (*stable*) atau divergen menuju ketidakseimbangan (*unstable*). Suatu model VAR(p) dapat ditulis sebagai berikut:

$$\begin{pmatrix} Y_{1t} \\ Y_{2t} \\ \vdots \\ Y_{nt} \end{pmatrix} = \begin{pmatrix} \phi_{11} & \beta_{11} & \dots & \alpha_{11} \\ \phi_{12} & \beta_{12} & \dots & \alpha_{12} \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{1n} & \beta_{1n} & \dots & \alpha_{1n} \end{pmatrix} \begin{pmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ \vdots \\ Y_{n,t-1} \end{pmatrix} + \dots \\
 + \begin{pmatrix} \phi_{p1} & \beta_{p1} & \dots & \alpha_{p1} \\ \phi_{p2} & \beta_{p2} & \dots & \alpha_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{pn} & \beta_{pn} & \dots & \alpha_{pn} \end{pmatrix} \begin{pmatrix} Y_{1,t-p} \\ Y_{2,t-p} \\ \vdots \\ Y_{n,t-p} \end{pmatrix} + \begin{pmatrix} e_{1t} \\ e_{2t} \\ \vdots \\ e_{nt} \end{pmatrix} \quad (2.12.1)$$

dengan menggunakan proses pembeda $BY_t = Y_t - Y_{t-1}$, persamaan 2.12.1 dapat ditulis sebagai berikut:

$$\begin{pmatrix} Y_{1t} \\ Y_{2t} \\ \vdots \\ Y_{nt} \end{pmatrix} = \begin{pmatrix} \phi_{11} & \beta_{11} & \dots & \alpha_{11} \\ \phi_{12} & \beta_{12} & \dots & \alpha_{12} \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{1n} & \beta_{1n} & \dots & \alpha_{1n} \end{pmatrix} \begin{pmatrix} BY_{1,t} \\ BY_{2,t} \\ \vdots \\ BY_{n,t} \end{pmatrix} + \dots \\
 + \begin{pmatrix} \phi_{p1} & \beta_{p1} & \dots & \alpha_{p1} \\ \phi_{p2} & \beta_{p2} & \dots & \alpha_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{pn} & \beta_{pn} & \dots & \alpha_{pn} \end{pmatrix} \begin{pmatrix} B^p Y_{1,t} \\ B^p Y_{2,t} \\ \vdots \\ B^p Y_{n,t} \end{pmatrix} + \begin{pmatrix} e_{1t} \\ e_{2t} \\ \vdots \\ e_{nt} \end{pmatrix} \quad (2.12.2)$$

Dalam notasi matriks, persamaan 2.12.2 dapat ditulis menjadi seperti berikut:

$$\underline{\mathbf{IY}}_t = B\mathbf{A}_1\underline{\mathbf{Y}}_t + B^2\mathbf{A}_2\underline{\mathbf{Y}}_t + \dots + B^p\mathbf{A}_p\underline{\mathbf{Y}}_t + \underline{\mathbf{e}}$$

$$\Longleftrightarrow (\mathbf{I} - B\mathbf{A}_1 - B^2\mathbf{A}_2 - \dots - B^p\mathbf{A}_p) \underline{Y}_t = \underline{e}$$

dengan $\mathbf{A}_i$ adalah matriks koefisien dari $\underline{Y}_t$ untuk $i = 1, \dots, p$, $\mathbf{I}$ adalah matriks identitas berukuran $n \times n$ dan $\phi[B] = \det(\mathbf{I} - B\mathbf{A}_1 - B^2\mathbf{A}_2 - \dots - B^p\mathbf{A}_p)$ adalah polinom karakteristik untuk model VAR(p).

Model VAR dikatakan stabil apabila modulus dari akar-akar karakteristik $\phi[B]$ kurang dari 1 atau semua akar-akar karakteristik berada dalam *unit circle* (lingkaran dengan jari-jari 1 pada bidang kompleks).

2.13 Uji Kausalitas *Granger*

Pendekatan *Granger* untuk kausalitas berdasarkan pemikiran bahwa kemungkinan peramalan adalah sejalan dengan kausalitas dan bahwa hubungan antara sebab dan akibat adalah sedemikian rupa dimana sebuah akibat tidak dapat terjadi sebelum ada sebab. Kausalitas dalam ekonometrika menurut *Granger* (1969) didefinisikan sebagai berikut.

Definisi 2.13.1. [6] *X* dikatakan Grange cause *Y* jika nilai sekarang *Y* dapat diprediksi lebih akurat dengan menggunakan nilai lalu *X* daripada kalau nilai lalu *X* tidak digunakan.

Uji kausalitas digunakan untuk mengetahui diantara dua variabel yang berhubungan, variabel mana yang menyebabkan variabel lain berubah. Uji kausalitas dapat dilakukan dengan berbagai metode diantaranya metode *Grangers Causality* dan *Error Correction Model Causality*. Diantara beberapa metode

pengujian yang ada, metode *Grangers Causality* yang paling populer. Pada pengujian ini dapat dilihat apakah suatu variabel mempunyai hubungan dua arah atau hanya satu arah saja.

Model dasar uji kausalitas adalah [8]:

$$Y_t = \sum_{i=1}^m a_i Y_{t-i} + \sum_{j=1}^m b_j X_{t-j} + v_t \quad (2.13.1)$$

$$X_t = \sum_{j=1}^m c_j X_{t-j} + \sum_{i=1}^m d_i Y_{t-i} + \mu_t \quad (2.13.2)$$

dengan:

X_t = variabel X pada waktu ke- t

Y_t = variabel Y pada waktu ke- t

m = jumlah *lag*

μ dan v_t = variabel pengganggu pada waktu ke- t

a, b, c dan d = koefisien masing-masing variabel diasumsikan bahwa μ_t dan v_t tidak berkorelasi

Gangguan μ_t dan v_t diasumsikan tidak berkorelasi. Kedua bentuk model ini akan menghasilkan empat kemungkinan mengenai nilai koefisien-koefisien yaitu:

1. $\sum_{i=1}^m b_i \neq 0$ dan $\sum_{j=1}^m d_j = 0$

Terdapat kausalitas satu arah dari variabel X terhadap variabel Y .

2. $\sum_{i=1}^m b_i = 0$ dan $\sum_{j=1}^m d_j \neq 0$

Terdapat kausalitas satu arah dari variabel Y terhadap variabel X .

3. $\sum_{i=1}^m b_i = 0$ dan $\sum_{j=1}^m d_j = 0$

Tidak terdapat kausalitas baik antara variabel X terhadap variabel Y maupun antara variabel Y terhadap variabel X .

4. $\sum_{i=1}^m b_i \neq 0$ dan $\sum_{j=1}^m d_j \neq 0$

Terdapat kausalitas dua arah baik antara variabel X terhadap variabel Y maupun antara variabel Y terhadap variabel X .

Hipotesis pada uji kausalitas adalah sebagai berikut:

H_0 : suatu variabel tidak menyebabkan atau mempengaruhi satu variabel lainnya

H_1 : suatu variabel menyebabkan atau mempengaruhi satu variabel lainnya

Statistik uji yang digunakan adalah statistik uji F. Kesimpulan diambil dari membandingkan nilai statistik F dengan nilai kritis F-tabel pada tingkat signifikan tertentu. Kriteria uji yang digunakan yaitu H_0 ditolak jika nilai statistik $F > \text{nilai } F \text{ tabel}$. Jika seluruh variabel memiliki nilai F-statistik lebih besar dari nilai F-tabel pada tingkat signifikan tertentu, maka kedua variabel tersebut memiliki kausalitas dua arah.

2.14 Analisis *Impulse Response Functions* (IRF)

Setelah melakukan pemodelan menggunakan model VAR, dibutuhkan metode yang dapat menjelaskan struktur dinamis yang dihasilkan oleh model VAR. Respon setiap variabel endogen terhadap gangguan dari variabel itu sendiri dan variabel endogen lainnya dapat ditunjukkan oleh IRF. IRF dapat juga menemukan suatu gangguan pada satu variabel endogen sehingga da-

pat menentukan bagaimana suatu perubahan yang tidak diharapkan dalam variabel mempengaruhi variabel lainnya sepanjang waktu. Oleh karena itu, IRF digunakan alat untuk melihat pengaruh dari sebuah variabel terikat jika mendapatkan guncangan dari variabel bebas sebesar satu standar deviasi[6].

2.15 Analisis *Varians Decompositions*

Analisis *variance decompositions* menggambarkan relatif pentingnya setiap variabel di dalam sistem VAR karena adanya gangguan (*shock*). Analisis ini memberikan metode yang berbeda di dalam menggambarkan sistem dinamis VAR dibandingkan dengan analisis IRF sebelumnya. *Variance decompositions* digunakan untuk memprediksi kontribusi presentase varian setiap variabel karena adanya perubahan variabel tertentu di dalam sistem VAR[6].

2.16 *Mean Absolute Percentage Error (MAPE)*

MAPE adalah suatu ukuran yang berguna untuk mengukur kesalahan nilai dugaan model. Kesalahan nilai dugaan model dinyatakan dalam bentuk rata-rata presentase *error* mutlak yang dituliskan sebagai berikut[9]:

$$MAPE = \frac{\sum_{t=1}^N \left| \left(\frac{Y_t - \hat{Y}_t}{Y_t} \right) \times 100\% \right|}{N} \quad (2.16.1)$$

dimana: N = banyaknya ramalan yang dilakukan

Y_t = data sebenarnya

$\hat{Y}_t$ = data hasil ramalan

Kriteria mengukur ketepatan peramalan dengan MAPE adalah sebagai berikut:

1. Ketepatan peramalan sangat baik saat nilai $MAPE \leq 10\%$
2. Ketepatan peramalan baik saat nilai $MAPE$ berkisar antara $10\% < MAPE \leq 20\%$
3. Ketepatan peramalan cukup saat nilai $MAPE$ berkisar antara $20\% < MAPE \leq 50\%$
4. Ketepatan peramalan buruk saat nilai $MAPE > 50\%$

