

## BAB III

### DATA DAN METODOLOGI

#### 3. 1 Data penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang diambil dari berbagai basis data di berbagai sumber. Data yang digunakan merupakan data *time series* dengan periode penelitian mulai dari Januari 2001 sampai dengan Desember 2007. Semua data merupakan *series* bulanan.

Data IHSG diambil dari *Yahoo! Finance*. Data IHSG merepresentasikan imbal hasil pasar modal di Indonesia. Untuk variabel KURS, yang merupakan nilai tukar nominal, data yang digunakan merupakan data nilai tengah kurs USD/IDR. Data KURS diambil dari *International Financial Statistic* yang dikelola dan disediakan oleh IMF. Data SBI dengan tenor satu bulan, diambil dari Statistik Ekonomi dan Keuangan Indonesia (SEKI). Untuk data MPI dan M1, data bersumber dari *International Financial Statistic*. MPI adalah *proxy* dari produktivitas industri, sedangkan M1 merupakan jumlah uang yang beredar di masyarakat dengan periode bulanan yang menggambarkan pertumbuhan inflasi. Untuk MPI, metode pengambilan sampel yang dilakukan bulanan menggunakan 2000 *sampling frame* dan berdasarkan ISIC *revised 3*, indeks maksimal berjumlah 2 *digit*. Pemilihan sampel dilakukan dalam 3 tahap, yang pertama yaitu pemilihan *establishment* dengan nilai output lebih besar atau sama dengan Rp. 750,09 miliar. Pada tahap selanjutnya *establishment* yang dipilih adalah *establishment* dalam 1% teratas output/worker. Langkah terakhir adalah pemilihan kembali dengan metode *Probability Proportional to Size*. Selanjutnya, indeks produktivitas dihitung dengan menggunakan “*Divisia Method*”, dimana perhitungan didasarkan kepada estimasi pertumbuhan komoditas

tiap bulannya. *Morgan Stanley Capital International World Index* (MXWD) merupakan *proxy* dari pasar modal dunia. Indeks ini dipilih karena jangkauannya yang luas. Data MXWD di-*download* dari situs *Bloomberg*.

### **3. 2 Metode pengolahan data**

Adapun langkah-langkah di dalam pemodelan VAR/VECM meliputi uji stasioneritas dari setiap *series* data, penentuan *lag* optimal, pengujian kestabilan model, pengujian kointegrasi. Apabila terdapat kointegrasi, maka model yang digunakan adalah model VECM yang merupakan model yang dapat mengoreksi adanya dinamika pada jangka pendek agar kembali ke keseimbangan jangka panjang.

Selanjutnya adalah penggunaan *Impulse Response Function* (IRF) dan *Variance Decomposition*. IRF berfungsi untuk melacak respon saat ini dan masa depan setiap variabel akibat perubahan atau *shock* suatu variabel tertentu, sedangkan *Variance Decomposition* berfungsi untuk prediksi kontribusi persentase varians setiap variabel terhadap perubahan suatu variabel tertentu.

#### **3. 2. 1 Vector Autoregression (VAR)**

Di dalam model persamaan simultan, umumnya variabel dibagi ke dalam dua macam variabel yaitu variabel eksogen yang sudah ditentukan sebelumnya dan variabel endogen. Namun, ketika tidak dapat dibedakan variabel mana yang terlebih dahulu mempengaruhi variabel yang lain, VAR/VECM merupakan solusinya. Di dalam model VAR/VECM tidak dikenal variabel eksogen dan variabel endogen. Oleh karena itu, semua variabel yang

digunakan dalam model VAR/VECM diperlakukan sama. Setiap variabel dan regressor (data variabel-variabel penjelas pada masa yang lalu) memiliki kesempatan yang sama untuk mempengaruhi variabel yang lain.

Misalkan model dengan 2 variabel (*bivariate*),  $y$  dan  $z$ , yang memiliki hubungan kausalitas simultan seperti berikut:

$$y_t = b_{10} - b_{12}z_t + \gamma_{11}y_{t-1} + \gamma_{12}z_{t-1} + \varepsilon_{yt} \dots\dots\dots(3. 1)$$

$$z_t = b_{20} - b_{21}y_t + \gamma_{21}y_{t-1} + \gamma_{22}z_{t-1} + \varepsilon_{zt} \dots\dots\dots(3. 2)$$

diasumsikan bahwa (a)  $y_t$  dan  $z_t$  stasioner; (b)  $\varepsilon_{yt}$  dan  $\varepsilon_{zt}$  adalah residual (*error term*) yang bersifat *white noise*<sup>14</sup> dengan standar deviasi  $\sigma_y$  dan  $\sigma_z$ ; (c)  $\{\varepsilon_{yt}\}$  dan  $\{\varepsilon_{zt}\}$  tidak terkorelasi.

Model persamaan tersebut dapat dibentuk ke dalam notasi matriks berikut:

$$\underbrace{\begin{bmatrix} 1 & b_{12} \\ b_{21} & 1 \end{bmatrix}}_B \underbrace{\begin{bmatrix} y_t \\ z_t \end{bmatrix}}_{x_t} = \underbrace{\begin{bmatrix} b_{10} \\ b_{20} \end{bmatrix}}_{\Gamma_0} + \underbrace{\begin{bmatrix} \gamma_{11} & \gamma_{12} \\ \gamma_{21} & \gamma_{22} \end{bmatrix}}_{\Gamma_1} \underbrace{\begin{bmatrix} y_{t-1} \\ z_{t-1} \end{bmatrix}}_{x_{t-1}} + \underbrace{\begin{bmatrix} \varepsilon_{yt} \\ \varepsilon_{zt} \end{bmatrix}}_{\varepsilon_t}$$

atau

$$Bx_t = \Gamma_0 + \Gamma_1x_{t-1} + \varepsilon_t \dots\dots\dots(3. 3)$$

Dengan mengalikan inverse  $B$  pada notasi matriks persamaan (3. 3) diatas, akan diperoleh:

$$x_t = B^{-1}\Gamma_0 + B^{-1}\Gamma_1x_{t-1} + B^{-1}\varepsilon_t = A_0 + A_1x_{t-1} + e_t \dots\dots\dots(3. 4)$$

atau dalam bentuk persamaan *bivariate*:

---

<sup>14</sup> Residual yang memiliki rata-rata 0, varians yang konstan, serta non-otokorelasi serial.

$$y_t = a_{10} + a_{11}y_{t-1} + a_{12}z_{t-1} + e_{1t} \dots\dots\dots(3. 5)$$

$$z_t = a_{20} + a_{21}y_{t-1} + a_{22}z_{t-1} + e_{2t} \dots\dots\dots(3. 6)$$

Model pada persamaan (3. 1) dan (3. 2) disebut sebagai *structural* VAR atau sistem VAR dalam bentuk primitif. Sedangkan model pada persamaan (3. 5) dan (3. 6) disebut sebagai model VAR dalam bentuk standar atau *reduced form*. Perlu diingat bahwa  $\varepsilon_{yt}$  dan  $\varepsilon_{zt}$  *white noise*, maka  $e_t$  pun akan memiliki rata-rata 0, varians yang konstan, serta non-otokorelasi serial dengan persamaan sebagai berikut:

$$e_{1t} = (\varepsilon_{yt} - b_{12}\varepsilon_{zt}) / (1 - b_{12}b_{21}) \dots\dots\dots(3. 7)$$

$$e_{2t} = (\varepsilon_{zt} - b_{21}\varepsilon_{yt}) / (1 - b_{12}b_{21}) \dots\dots\dots(3. 8)$$

Di bawah ini adalah beberapa keunggulan dari model VAR antara lain:

1. Model VAR sangat sederhana. Dengan model ini, tidak perlu dikhawatirkan variabel mana yang bersifat *endogenous* dan variabel mana yang bersifat *exogenous*.
2. Estimasi dari model VAR juga sederhana karena setiap persamaan dapat diestimasi dengan metode OLS biasa secara terpisah.
3. Hasil *forecast* dari model VAR, dalam banyak kasus, lebih baik bila dibandingkan dengan model persamaan simultan yang lebih kompleks (Mahmoud (1984); Mcnees (1986)).

Sedangkan beberapa kelemahan model VAR, antara lain:

1. Tidak seperti persamaan simultan lainnya, pada model VAR digunakan sedikit informasi sebelumnya. Perlu diingat bahwa dalam persamaan simultan, dimasukkan atau dikeluarkannya sebuah variabel memiliki peranan yang penting dalam identifikasi model.
2. Karena VAR menekankan pada *forecasting*, model ini kurang cocok untuk analisis kebijakan.
3. Pemilihan panjang *lag* waktu optimal merupakan salah satu kelemahan terbesar model VAR.
4. Semua data harus stasioner, sehingga bila terdapat data yang tidak stasioner maka harus dilakukan *differencing*. Hal lain yang perlu digarisbawahi adalah, bahwa semua data harus terintegrasi (stasioner) pada derajat yang sama.
5. Karena koefisien individual dalam model VAR terkadang sulit diinterpretasikan, maka digunakan *impulse response function* (IRF). IRF menelusuri respon dependen variabel terhadap *shock* pada *error term*. Meskipun pada kenyataannya masih banyak para peneliti yang mempertanyakan mengenai kegunaan dari IRF, namun IRF merupakan salah satu inti dari model VAR.

### 3. 2. 2 Uji Stasioneritas Data

Sebuah data disebut stasioner secara kuat apabila memenuhi syarat-syarat sebagai berikut:

- a.  $\mu(t) = E(x_t)$ ; artinya memiliki nilai rerata (*mean*) yang konstan.

b.  $Cov(x_t, x_{t+k}) = \gamma_k$ ; artinya dengan *lag* yang sama, walaupun dengan periode yang berbeda, akan menghasilkan *covariance* yang konstan.

c.  $\rho(k) = \frac{\gamma(k)}{\gamma(0)} = \frac{Cov(x_t, x_{t-k})}{Var(x_t)}$ ; dimana  $Var(x_t) = \sigma^2$

Variabel-variabel makroekonomi memiliki kecenderungan data yang bersifat tren deterministik, yaitu data memiliki suatu kecenderungan pola bergerak ke arah yang sama seiring berjalannya waktu. Data yang bersifat non-stasioner atau memiliki tren dapat menghasilkan kesimpulan yang kurang tepat karena dapat menyebabkan masalah pada regresi. Untuk mengatasi hal tersebut, hal yang lazim dilakukan adalah melakukan penurunan data pada derajat pertama. Proses penurunan data dapat dilakukan dengan dua cara, yaitu:

- $dlog(P_t) = R_t = \ln \frac{P_t}{P_{t-1}}$ ; yang akan menghasilkan return dari suatu *series* atau dapat berarti juga fluktuasi dari suatu *series*
- $diff(P_t) = P_t - P_{t-1}$ ; yang digunakan untuk menghitung tingkat pertumbuhan absolut suatu *series*

Dalam penelitian ini, pengujian stasioneritas data menggunakan pengujian Augmented Dickey-Fuller (ADF). Selain itu, secara informal, stasioneritas data dapat dilakukan dengan melakukan plot data (grafik). Namun demikian, pengujian informal sebaiknya dilakukan pada awal pengujian dengan tujuan untuk memperkirakan stasioneritas *series* secara visual dan dilanjutkan dengan uji ADF.

Dickey and Fuller (1979, 1981) membuat sebuah prosedur tes non-stasioneritas. Mereka menyimpulkan bahwa tes untuk melihat stasioneritas data sama dengan tes untuk menguji ada

tidaknya *unit root*. Kemudian uji yang disebut dengan Dickey-Fuller (DF) test tersebut dikembangkan menjadi uji Augmented Dickey-Fuller (ADF). Di dalam ADF test dimasukkan *extra lagged terms* dari dependen variabel untuk mengeliminasi autokorelasi. Panjang *lag* dari *extra term* tersebut ditentukan oleh Akaike Information Criterion (AIC) atau Schwartz Criterion (SC). Tiga bentuk tes ADF yang mungkin meliputi persamaan dibawah ini:

$$1. \Delta y_t = \gamma y_{t-1} + \sum_{i=1}^p \beta_i \Delta y_{t-i} + u_t \dots\dots\dots (3. 9)$$

$$2. \Delta y_t = a_0 + \gamma y_{t-1} + \sum_{i=1}^p \beta_i \Delta y_{t-i} + u_t \dots\dots\dots (3. 10)$$

$$3. \Delta y_t = a_0 + \gamma y_{t-1} + a_{2t} + \sum_{i=1}^p \beta_i \Delta y_{t-i} + u_t \dots\dots\dots (3. 11)$$

Perbedaan dari ketiga persamaan di atas adalah keberadaan dari elemen deterministik  $a_0$  dan  $a_{2t}$ . Adapun hipotesis dalam uji stasioneritas adalah sebagai berikut:

$H_0$ :  $y_t$  has a unit root (data tidak stasioner)

$H_1$ :  $y_t$  has no unit root (data stasioner)

Kemudian dilakukan perbandingan antara *critical-value (t-crit)* dengan nilai *t-stat* dengan tingkat keyakinan sesuai dengan yang diinginkan. Apabila  $t-stat < t-crit$  maka  $H_0$  gagal diterima atau data stasioner.

Pada saat menggunakan uji ADF harus dipastikan bahwa *error term* tidak terkorelasi dan bahwa persamaan tersebut memiliki *variance* yang konstan.

### 3. 2. 3 Penentuan *lag* optimal

Untuk menentukan *lag* yang optimal diperlukan beberapa langkah. Langkah pertama untuk menentukan panjang *lag* optimal dilihat dari panjang *lag* maksimum sistem VAR yang stabil. Stabilitas sistem VAR dilihat dari nilai *inverse roots* karakteristik AR polinomialnya. Luthkepohl (1991) menyatakan bahwa suatu sistem VAR dikatakan stabil (stasioner) jika seluruh *roots*-nya memiliki *modulus* lebih kecil dari satu dan semuanya terletak di dalam *unit circle*.

Selanjutnya, panjang *lag* optimal akan dicari dengan menggunakan kriteria-kriteria Likelihood Ratio (LR), Final Prediction Error (FPE), Akaike Information Critrion (AIC), Schwarz Information Criterion (SC), dan Hannan-Quin Criterion (HQ). Jika kriteria informasi hanya merujuk pada sebuah kandidat *lag* maka, kandidat tersebutlah yang optimal. Jika diperoleh lebih dari satu kandidat, maka pemilihan dilanjutkan pada tahap ketiga.

Pada tahap terakhir ini, nilai Adjusted  $R^2$  variabel VAR dari masing-masing kandidat *lag* akan diperbandingkan, dengan penekanan pada variabel-variabel terpenting dari sistem VAR tersebut. *Lag* optimal akan dipilih dari sistem VAR dengan *lag* tertentu yang menghasilkan nilai Adjusted  $R^2$  terbesar pada variabel-variabel penting di dalam sistem.

### 3. 2. 4 Stabilitas Data

Di dalam model *autoregressive* derajat pertama  $y_t = a_0 + a_1 y_{t-1} + \varepsilon_t$ , kondisi stabil terjadi ketika  $a_0$  bernilai kurang dari satu dalam nilai absolut. Terdapat sebuah analogi antara



stabilitas model dengan matriks  $A_1$  pada persamaan (3. 4). Dengan menggunakan menggunakan model dibawah ini:

$$x_t = A_0 + A_1(A_0 + A_1x_{t-2} + e_{t-1}) + e_t \dots\dots\dots(3. 12)$$

$$= (I + A_1)A_0 + A_1^2x_{t-2} + A_1e_{t-1} + e_t \dots\dots\dots(3.13)$$

dimana  $I = 2 \times 2$  matiks identitas.

Setelah dilakukan iterasi sebanyak  $n$ ,

$$x_t = (I + A_1 + \dots + A_1^n)A_0 + \sum_{i=0}^n A_1^i e_{t-i} + A_1^{n+1} x_{t-n-1} \dots\dots\dots(3. 14)$$

jika iterasi ke belakang dilanjutkan, akan terlihat bahwa konvergensi membutuhkan  $A_1^n$  menghilang karena  $n$  mendekati *infinite*. Seperti terlihat di bawah ini, stabilitas model mensyaratkan *roots* dari  $(1 - a_{11}L)(1 - a_{22}L) - (a_{12}a_{21}L^2)$  berada di luar *unit circle*. Bila diasumsikan kondisi stabilitas terpenuhi, maka solusi untuk  $x_t$  dapat ditulis sebagai berikut:

$$x_t = \mu + \sum_{i=0}^{\infty} A_1^i e_{t-i} \dots\dots\dots(3. 15)$$

dimana  $\mu = [\bar{y} \bar{z}]'$

dan  $\bar{y} = [a_{10}(1 - a_{22}) + (a_{12}a_{20})] / \Delta$ ;

$\bar{z} = [a_{20}(1 - a_{11}) + a_{21}a_{10}] / \Delta$ ;

$\Delta = (1 - a_{11})(1 - a_{22}) - a_{12}a_{21}$

Dari persamaan (3. 15), *unconditional mean* dari  $x_t$  adalah  $\mu$ , sehingga *unconditional means* dari  $y_t$  dan  $z_t$  adalah  $\bar{y}$  dan  $\bar{z}$ . Untuk mendapatkan perspektif lain dari stabilitas model, maka dapat digunakan model berikut. Dengan memasukkan operator *lag* pada persamaan (3. 5) dan (3. 6) maka didapatkan persamaan berikut:

$$y_t = a_{10} + a_{11}Ly_t + a_{12}Lz_t + e_{1t} \dots\dots\dots(3. 16)$$

$$z_t = a_{20} + a_{21}Ly_t + a_{22}Lz_t + e_{2t} \dots\dots\dots(3. 17)$$

atau

$$(1 - a_{11}L)y_t = a_{10} + a_{12}Lz_t + e_{1t} \dots\dots\dots(3. 18)$$

$$(1 - a_{22}L)z_t = a_{20} + a_{21}Ly_t + e_{2t} \dots\dots\dots(3. 19)$$

Dari kedua persamaan di atas, maka dapat dibuat solusi untuk  $z_t$  menggunakan  $Lz_t$  yaitu sebagai berikut:

$$Lz_t = L(a_{20} + a_{21}Ly_t + e_{2t})/(1 - a_{22}L) \dots\dots\dots(3. 20)$$

sehingga

$$(1 - a_{11}L)y_t = a_{10} + a_{12}L[a_{20} + a_{21}Ly_t + e_{2t}]/(1 - a_{22}L) + e_{1t} \dots\dots\dots(3. 21)$$

bila diperhatikan dari penurunan - penurunan notasi di atas, VAR derajat pertama dalam  $\{y_t\}$  dan  $\{z_t\}$  telah diubah ke dalam persamaan *difference* stokastik derajat kedua dalam bentuk persamaan  $\{y_t\}$ . Secara eksplisit, maka untuk menyelesaikan  $y_t$  didapatkan:

$$y_t = \frac{a_{10}(1 - a_{22}) + a_{12}a_{20} + (1 - a_{22}L)e_{1t} + a_{12}e_{2t-1}}{(1 - a_{11}L)(1 - a_{22}L) - a_{12}a_{21}L^2} \dots\dots\dots(3. 22)$$

atau dengan kata lain, dapat ditemukan solusi untuk  $z_t$ , yaitu:

$$z_t = \frac{a_{20}(1 - a_{11}) + a_{21}a_{10} + (1 - a_{11}L)e_{1t} + a_{21}e_{1t-1}}{(1 - a_{11}L)(1 - a_{22}L) - a_{12}a_{21}L^2} \dots\dots\dots(3. 23)$$

Setelah menentukan *lag* optimal dan pengujian kestabilan model VAR melalui kriteria-kriteria yang ada, maka perlu di uji keberadaan kointegrasi. Dalam banyak kasus, jika dua variabel yang terintegrasi pada derajat pertama  $\{I(1)\}$  – atau tidak stasioner pada data level – dikombinasikan secara linier, maka kombinasi tersebut juga akan terintegrasi pada derajat pertama  $\{I(1)\}$ . Namun apabila kombinasi linier dari variabel terintegrasi pada derajat 0  $\{I(0)\}$  maka dapat dipastikan bahwa terdapat kointegrasi antara variabel tersebut. Misalkan, terdapat dua buah series:  $x_t \sim I(1)$  dan  $y_t \sim I(1)$  dimana  $y_t = \alpha + \beta x_t + \varepsilon_t$ . Apabila  $\varepsilon_t \sim I(0)$ , maka terdapat hubungan kointegrasi diantara kedua variabel tersebut. Sedangkan bila  $\varepsilon_t \sim I(1)$  maka persamaan tersebut disebut *spurious regression*. *Spurious regression* ditandai dengan nilai  $R^2$  yang tinggi namun memiliki *t-stat* yang tidak signifikan.

Pada dasarnya uji kointegrasi bertujuan melihat apakah variabel-variabel yang bersifat non-stasioner memiliki hubungan jangka panjang yaitu berupa hasil yang hubungan kointegrasi stasioner (dilihat dari *error term*) pada jangka panjang. Apabila variabel-variabel tersebut terintegrasi pada derajat pertama dan *error term*-nya juga terintegrasi pada derajat pertama maka persamaan tersebut disebut *spurious regression*.

### 3. 2. 5 Uji Kointegrasi

Untuk menguji ada tidaknya hubungan kointegrasi data yang digunakan harus dalam bentuk level data. Pengujian dapat dilakukan dengan metode Engle-Granger (1987), dan pendekatan Juselius Johansen (1988).

Jika di dalam sebuah model terdapat lebih dari dua variabel, maka akan terdapat kemungkinan adanya lebih dari satu hubungan kointegrasi di dalam model tersebut. Secara umum, dengan jumlah variabel sebanyak  $n$ , maka jumlah hubungan kointegrasi di dalam model tersebut maksimal sebanyak  $(n - 1)$ . Jika jumlah variabel di dalam model lebih banyak dari dua ( $n > 2$ ) maka model tersebut tidak dapat diselesaikan dengan metode Engle-Granger karena metode ini hanya dapat mengakomodir maksimal sebanyak dua variabel dengan pendekatan *single equation*-nya. Oleh karena itu, di dalam penelitian ini digunakan pendekatan *Johansen Cointegration Test*.

Pengujian hubungan kointegrasi dengan pendekatan *Johansen Cointegration Test* dilakukan dengan menggunakan *lag* optimal sesuai dengan pengujian sebelumnya – pengujian stabilitas model dengan menggunakan model VAR. Sementara penentuan asumsi deterministik yang melandasi pembentukan persamaan kointegrasi didasarkan pada nilai kriteria informasi *Akaike Information Criteria (AIC)* dan *Schwarz Criterion (SC)*. Berdasarkan asumsi deterministik tersebut akan diperoleh informasi mengenai banyaknya hubungan kointegrasi antarvariabel sesuai dengan metode *Trace* dan *Max*.

Ketidakyakinan penggunaan asumsi deterministik yang tepat pada suatu *series* menyebabkan berkembangnya penggunaan pengujian hubungan kointegrasi secara umum (*summary test*). Dengan menggunakan metode ini, jumlah hubungan kointegrasi dan asumsi

deterministik *series* dapat diketahui dengan menggunakan berbagai nilai kriteria informasi yang tersedia.

### 3. 2. 6 Vector Error Correction Model (VECM)

Penggunaan model VAR mensyaratkan *stationarity* pada variabel-variabelnya. Maddala (2001) menyebutkan proses *differencing* yang digunakan untuk mencapai syarat stasioneritas akan menghilangkan sejumlah informasi penting mengenai pergerakan variabel dalam jangka panjang. Berbeda dengan model VAR, VECM tidak mensyaratkan hal tersebut sehingga VECM dapat menangkap informasi jangka panjang.

Jika dua buah variabel  $x_t$  dan  $y_t$  terkointegrasi, yang berarti memiliki hubungan jangka panjang, maka *short-run dynamics* dapat digambarkan melalui *error correction model* (ECM). Hal ini dikenal dengan *Granger representation theorem*. Jika  $x_t \sim I(1)$ ,  $y_t \sim I(1)$ , dan  $y_t = \beta_1 + \beta_2 x_t + e_t$  dimana  $\Delta y_t \sim I(0)$  dan  $\Delta x_t \sim I(0)$  maka *Granger representation theorem* mengatakan bahwa  $x_t$  dan  $y_t$  dapat dibuat ke dalam bentuk persamaan jangka pendek ECM seperti berikut:

$$\Delta y_t = a_1 + a_2 \Delta x_t + \Delta e_t \dots\dots\dots(3. 24)$$

dan dalam model jangka panjang sebagai berikut:

$$y_t^* = \beta_1 + \beta_2 x_t \dots\dots\dots(3. 25)$$

Jika diasumsikan bahwa kombinasi dari  $x_t$  dan  $y_t$  memiliki kombinasi linier yang terintegrasi pada derajat nol, maka dapat dibentuk sebuah persamaan yang akan menghubungkan  $x_t$  dan  $y_t$  dalam jangka panjang melalui *error term*  $e_t = y_t - \hat{\beta}_1 - \hat{\beta}_2 x_t$ .

Untuk memperjelas bagaimana kointegrasi terjadi pada sebuah model dengan jumlah variabel lebih dari dua ( $n > 2$ ), maka diasumsikan terdapat tiga buah variabel  $y_t$ ,  $x_t$ , dan  $w_t$  dimana  $z_t$  adalah sebuah matriks dengan notasi  $z_t = [y_t, x_t, w_t]$  yang dapat dijabarkan dalam model sebagai berikut:

$$z_t = A_1 z_{t-1} + A_2 z_{t-2} + \dots + A_k z_{t-k} + e_t \dots \dots \dots (3. 26)$$

Kemudian, persamaan di atas dapat dibentuk dalam *error correction model* sebagai berikut:

$$\Delta z_t = \Gamma_1 \Delta z_{t-1} + \Gamma_2 \Delta z_{t-2} + \dots + \Gamma_{k-1} \Delta z_{t-k-1} + \Pi z_{t-1} + e_t \dots \dots \dots (3. 27)$$

dimana  $\Gamma_i = (I - A_1 - A_2 - \dots - A_k)$  ( $i = 1, 2, \dots, k - 1$ ) dan  $\Pi = -(I - A_1 - A_2 - \dots - A_k)$ .

Matriks  $\Pi$  memuat informasi mengenai hubungan jangka panjang. Kemudian untuk melihat lebih detail komponen di dalamnya, maka matriks tersebut didekomposisi dalam bentuk  $\Pi = \alpha \beta'$  dimana  $\alpha$  merupakan koefisien *speed of adjustment* terhadap equilibrium jangka panjang dan  $\beta'$  merupakan matriks koefisien jangka panjang.

Untuk itu, notasi  $\beta' z_{t-1}$  ekuivalen dengan *error correction term*  $(y_{t-1} - \beta_0 - \beta_1 x_{t-1})$  seperti pada model *bivariate* pada persamaan (3. 24), kecuali bahwa sekarang notasi  $\beta' z_{t-1}$  memuat vektor hingga sebanyak  $(n - 1)$ . Untuk mempermudah, maka

diasumsikan bahwa  $k = 2$ , sehingga model *multivariate* pada persamaan (3. 25) dapat dinotasikan dalam matriks berikut:

$$\begin{bmatrix} \Delta y_t \\ \Delta x_t \\ \Delta w_t \end{bmatrix} = \Gamma_1 \begin{bmatrix} \Delta y_{t-1} \\ \Delta x_{t-1} \\ \Delta w_{t-1} \end{bmatrix} + \Pi \begin{bmatrix} y_{t-1} \\ x_{t-1} \\ w_{t-1} \end{bmatrix} + \varepsilon_t$$

atau

$$\begin{bmatrix} \Delta y_t \\ \Delta x_t \\ \Delta w_t \end{bmatrix} = \Gamma_1 \begin{bmatrix} \Delta y_{t-1} \\ \Delta x_{t-1} \\ \Delta w_{t-1} \end{bmatrix} + \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \\ a_{31} & a_{23} \end{bmatrix} \begin{bmatrix} \beta_{11} & \beta_{21} & \beta_{31} \\ \beta_{12} & \beta_{22} & \beta_{32} \end{bmatrix} \begin{bmatrix} y_{t-1} \\ x_{t-1} \\ w_{t-1} \end{bmatrix} + \varepsilon_t$$

Kemudian, dengan merujuk pada persamaan (3. 25), maka didapatkan persamaan berikut:

$$\Pi_1 z_{t-1} = \begin{bmatrix} a_{11}\beta_{11} + a_{12}\beta_{12} & a_{11}\beta_{21} + a_{12}\beta_{22} & a_{11}\beta_{31} + a_{12}\beta_{32} \end{bmatrix} \begin{bmatrix} y_{t-1} \\ x_{t-1} \\ w_{t-1} \end{bmatrix}$$

dimana  $\Pi_1$  adalah baris pertama pada matriks  $\Pi$ . Matriks di atas dapat disederhanakan ke dalam persamaan:

$$\Pi_1 z_{t-1} = a_{11}(\beta_{11}y_{t-1} + \beta_{21}x_{t-1} + \beta_{31}w_{t-1}) + a_{12}(\beta_{12}y_{t-1} + \beta_{22}x_{t-1} + \beta_{32}w_{t-1}) \dots\dots\dots(3. 28)$$

dari persamaan di atas, dapat dilihat dengan jelas vektor kointegrasi dengan *speed of adjustment*  $a_{11}$  dan  $a_{12}$ . *Speed of adjustment* merupakan sebuah *tool* yang dimiliki oleh model ECM untuk melihat seberapa cepat *short term dynamics* dapat menyesuaikan diri dan kembali ke *long run equilibrium*.

Semakin besar nilai koefisien *speed of adjustment* maka semakin besar respon dari deviasi periode sebelumnya terhadap equilibrium jangka panjang. Dengan kata lain, semakin besar penyesuaian yang terjadi pada *short term dynamics* untuk kembali ke *long run equilibrium*. Sebaliknya, nilai *speed of adjustment* yang kecil menunjukkan deviasi yang terjadi pada jangka pendek bersifat tidak responsif atau lambat dalam menyesuaikan pada *long run equilibrium*. Dan bila keduanya bernilai nol, maka tidak terdapat keseimbangan jangka panjang dan model tersebut tidak dapat dikategorikan sebagai ECM atau kointegrasi.

Menurut Asteriou dan Hall (2007), beberapa keuntungan dalam penggunaan ECM adalah:

1. ECM merupakan sebuah model yang baik digunakan dalam melakukan koreksi terhadap ketidakseimbangan pada periode sebelumnya yang memiliki implikasi ekonomi yang sangat baik.
2. Bila dalam pemodelan ECM digunakan data dalam bentuk *difference*, maka model tersebut dapat mengeliminasi masalah *spurious regression*.
3. ECM merupakan model yang dengan mudah dapat dipasangkan dengan pendekatan ekonometri yang paling umum hingga yang spesifik. Sehingga ECM dapat digunakan untuk mencari model yang bersifat *parsimonous*<sup>15</sup>.
4. Karena *disequilibrium* dari *error term* model bersifat stasioner (dari definisi kointegrasi), maka ECM memiliki implikasi: proses penyesuaian pada *short term dynamics* menghindarkan *error* yang semakin besar pada hubungan jangka panjang.

---

<sup>15</sup> *Parsimonous theory* menyatakan bahwa semakin sederhana model, maka semakin baik model tersebut. Antara lain disebabkan karena semakin banyak variabel yang dimasukkan dalam model maka akan semakin besar pula standar *error* dari parameter yang diestimasi dan semakin banyak variabel independen dari suatu model, maka kemampuan *forecast*-nya akan semakin berkurang.



### 3. 2. 6 Impulse Response Function (IRF)

Pada dasarnya model VAR dapat ditulis ke dalam bentuk Vector Moving Average (VMA). Persamaan (3. 16) merupakan representasi VMA dari persamaan (3. 4) dimana variabel-variabelnya ditulis dalam bentuk nilai sekarang dan masa lalu dari dua tipe *shock* (contohnya:  $e_{1t}$  dan  $e_{2t}$ ). Representasi dari VMA dapat digunakan untuk menelusuri jalur waktu dari berbagai *shock* pada variabel-variabel di dalam model VAR. Bila model VAR dengan 2 variabel dituliskan dalam bentuk matriks, maka:

$$\begin{bmatrix} y_t \\ z_t \end{bmatrix} = \begin{bmatrix} a_{10} \\ a_{20} \end{bmatrix} + \begin{bmatrix} a_{11} & a_{21} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} y_{t-1} \\ z_{t-1} \end{bmatrix} + \begin{bmatrix} e_{1t} \\ e_{2t} \end{bmatrix} \dots\dots\dots(3. 29)$$

dengan memasukkan persaaan (3. 11) maka didapatkan

$$\begin{bmatrix} y_t \\ z_t \end{bmatrix} = \begin{bmatrix} \bar{y} \\ \bar{z} \end{bmatrix} + \sum_{i=0}^{\infty} \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}^i + \begin{bmatrix} e_{1t-i} \\ e_{2t-i} \end{bmatrix} \dots\dots\dots(3. 30)$$

Persamaan (3. 30) menjelaskan variabel  $y_t$  dan  $z_t$  dalam bentuk  $\{e_{1t}\}$  dan  $\{e_{2t}\}$ . Dengan menggunakan persamaan (3. 7) dan (3. 8) maka vektor dari *error* dapat ditulis dalam matriks berikut:

$$\begin{bmatrix} e_{1t} \\ e_{2t} \end{bmatrix} = \frac{1}{1 - b_{12}b_{21}} \begin{bmatrix} 1 & -b_{12} \\ -b_{12} & 1 \end{bmatrix} \begin{bmatrix} \varepsilon_{y_t} \\ \varepsilon_{z_t} \end{bmatrix} \dots\dots\dots(3. 31)$$

Dan dari kombinasi persamaan (3. 30) dan (3. 31) diatas, akan menghasilkan persamaan:

$$\begin{bmatrix} y_t \\ z_t \end{bmatrix} = \begin{bmatrix} \bar{y}_t \\ \bar{z}_t \end{bmatrix} + \frac{1}{1 - b_{12}b_{21}} \sum_{i=0}^{\infty} \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}^i \begin{bmatrix} 1 & -b_{12} \\ -b_{21} & 1 \end{bmatrix} \begin{bmatrix} \varepsilon_{y_{t-i}} \\ \varepsilon_{z_{t-i}} \end{bmatrix} \dots\dots\dots(3. 32)$$

untuk menyederhanakan persamaan matriks di atas, maka matriks 2.2  $\phi_i$  diisubsitusi dengan menggunakan elemen  $\phi_{jk}(i)$  berikut:

$$\phi_i = \frac{A_1^i}{1 - b_{12}b_{21}} \begin{bmatrix} 1 & -b_{12} \\ -b_{21} & 1 \end{bmatrix} \dots\dots\dots(3.33)$$

Sehingga representasi dari *moving average* dari persamaan (3.31) dan (3.32) dapat dituliskan dalam bentuk  $\{\varepsilon_{y_t}\}$  dan  $\{\varepsilon_{z_t}\}$  sebagai berikut:

$$\begin{bmatrix} y_t \\ z_t \end{bmatrix} = \begin{bmatrix} \bar{y} \\ \bar{z} \end{bmatrix} + \sum_{i=0}^{\infty} \begin{bmatrix} \phi_{11}(i) & \phi_{21}(i) \\ \phi_{21}(i) & \phi_{22}(i) \end{bmatrix} \begin{bmatrix} \varepsilon_{y_{t-i}} \\ \varepsilon_{z_{t-i}} \end{bmatrix} \dots\dots\dots(3.34)$$

atau dalam bentuk persamaan:

$$x_t = \mu + \sum_{i=0}^{\infty} \phi_i \varepsilon_{t-i} \dots\dots\dots(3.35)$$

Keempat set dari koefisien  $\phi_{11}(i)$ ,  $\phi_{12}(i)$ ,  $\phi_{21}(i)$ , dan  $\phi_{22}(i)$  disebut sebagai *impulse response function*. Membuat plot dari IRF adalah cara praktis untuk melihat bagaimana representasi visual dari respon *series*  $\{y_t\}$  dan  $\{z_t\}$  terhadap berbagai *shock* yang terjadi. Dengan demikian IRF dapat digunakan sebagai alat untuk melihat efek saat ini dan masa lalu perubahan dalam *error term* dari waktu ke waktu terhadap variabel-variabel di dalam model VAR.

### **3. 2. 7 Variance Decomposition**

*Variance Decomposition* menjelaskan proporsi dari pergerakan secara *sequential* setiap variabel terhadap “*shock*-nya” sendiri dan terhadap *shock* variabel lain. Atau dengan kata lain dapat digunakan sebagai prediksi kontribusi persentase varians setiap variabel terhadap perubahan suatu variabel tertentu. Dengan demikian, dengan menggunakan salah satu *tool* dari VAR ini, dapat diketahui variabel mana yang memberikan efek paling besar terhadap suatu variabel.