BAB III

MODEL VOLATILITAS EXPONENTIAL GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY (EGARCH)

3.1 Proses Exponential GARCH

Exponential GARCH (EGARCH) diajukan Nelson pada 1991 untuk menutupi kelemahan model ARCH/GARCH dalam menangkap fenomona ketidaksimetrisan *good news* (error positif) dan *bad news* (error negatif). Model ARCH/GARCH mengasumsikan pengaruh *good news* dan *bad news* sama terhadap volatilitasnya sehingga tidak dapat menangkap fenomena ketidaksimetrisan.

Pada data *return*, nilai volatilitas akan tinggi ketika nilai error lebih kecil dari nol dibandingkan ketika error lebih besar dari nol. Keadaan yang disebut *Leverage Effect* ini ditangkap oleh model Exponential GARCH.

Untuk memperhitungkan efek asimetris antara *good news* dan *bad news*, Nelson mempertimbangkan inovasi terboboti (*weighted innovation*)

$$g(\varepsilon_t) = \theta\varepsilon_t + \gamma\left[|\varepsilon_t| - E(|\varepsilon_t|)\right] \qquad (3.1.1)$$

dengan θ dan γ adalah konstanta riil, ε_t dan $|\varepsilon_t| - E(|\varepsilon_t|)$ barisan berdistribusi identik independen dengan rata-rata nol dan kontinu. Dengan demikian $E[g(\varepsilon_t)] = 0$. Ketidaksimetrisan dari $g(\varepsilon_t)$ dapat dilihat dengan menulis kembali persamaan (3.1.1) sebagai

$$g(\varepsilon_t) = \begin{cases} (\theta+\gamma)\varepsilon_t - \gamma E(|\varepsilon_t|), \varepsilon_t \geq o \\ (\theta-\gamma)\varepsilon_t - \gamma E(|\varepsilon_t|), \varepsilon_t \leq o \end{cases} \tag{3.1.2}$$

Di samping dapat menangkap efek asimetris dari *good news* dan *bad news*, model Exponential GARCH memiliki kelebihan lain dibandingkan model ARCH/GARCH, yaitu parameter-parameter pada Exponential GARCH tidak perlu dibatasi untuk menjamin variansi selalu positif. Hal ini dikarenakan bentuk persamaan dalam logaritma.

3.1.1 Proses Exponential GARCH (1,1)

Misalkan Z_1, Z_2,…, Z_t adalah suatu runtun waktu; I_t merupakan himpunan informasi yang diketahui pada waktu t. proses Z_t dikatakan mengikuti proses EGARCH orde satu jika

$\varepsilon_t | I_{t-1} \sim N(0,\sigma^2)$ dengan

$$\ln\sigma_t^2 = \omega + \beta\ln\sigma_{t-1}^2 + \alpha\frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}} + \gamma\left[\left|\frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}}\right| - E\left|\frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}}\right|\right] \tag{3.1.3}$$

$$\sigma_t^2 = \sigma_{t-1}^{2\beta}\exp\left[\omega - E\left|\frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}}\right|\right]\exp\left[\frac{\alpha+\gamma}{\sqrt{\sigma_{t-1}^2}}|\varepsilon_{t-1}|\right]$$

Karena pada model volatilitas EGARCH error positif dan error negatif memberikan pengaruh yang berbeda terhadap volatilitas maka persamaan (3.1.3) dapat ditulis kembali dalam bentuk

$$\sigma_t^2 = \begin{cases} \sigma_{t-1}^{2\beta} \exp\left[\omega - \gamma E\left|\frac{\varepsilon_{t-1}}{\sigma_{t-1}}\right|\right] \exp\left[\frac{\alpha-\gamma}{\sqrt{\sigma_{t-1}}}\varepsilon_{t-1}\right], \varepsilon_t < o \\ \sigma_{t-1}^{2\beta} \exp\left[\omega - \gamma E\left|\frac{\varepsilon_{t-1}}{\sigma_{t-1}}\right|\right] \exp\left[\frac{\alpha+\gamma}{\sqrt{\sigma_{t-1}}}\varepsilon_{t-1}\right], \varepsilon_t \geq o \end{cases} \tag{3.1.4}$$

dengan σ_t^2 : variansi error pada waktu t

α : parameter untuk mengukur ketidaksimetrisan

γ : parameter untuk mengukur besarnya volatilitas

Karena $E\left|\frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}}\right| = 0$ maka persamaan (3.1.3) dapat juga ditulis dalam bentuk

$$\ln \sigma_t^2 = \sigma^2 + \alpha_1\left|\frac{\varepsilon_{t-1}}{\sigma_{t-1}}\right| + \gamma_1 \frac{\varepsilon_{t-1}}{\sigma_{t-1}} + \beta_1 \ln \sigma_{t-1}^2 \tag{3.1.5}$$

Persamaan (3.1.5) terdiri dari dua unsur, yaitu *magnitude effect* $\left|\frac{\varepsilon_{t-1}}{\sigma_{t-1}}\right|$ yang menunjukkan besarnya pengaruh volatilitas pada periode t-1 terhadap varian saat ini dan *sign effect* $\left(\frac{\varepsilon_{t-1}}{\sigma_{t-1}}\right)$ yang menunjukkan perbedaan pengaruh *good news* dan *bad news* pada periode t-1 terhadap varian saat ini.

Selanjutnya agar persamaan (3.1.3) mengikuti distribusi normal baku N(0,1) maka ε_t harus dibagi dengan simpangan bakunya.

Bukti:

Karena $\varepsilon_t | I_{t-1} \sim N(0,\sigma^2)$ maka fungsi pembangkit momen untuk ε_t adalah

$$M_\varepsilon(t) = E\left[e^{t\varepsilon}\right] = e^{1/2t^2\sigma^2}$$

Selanjutnya misalkan $Y = \frac{\varepsilon}{\sigma_t}$

$$M_Y(t) = E\left[e^{tY}\right] = E\left[e^{t\frac{\varepsilon}{\sigma}}\right] = E\left[e^{\frac{t}{\sigma}\varepsilon}\right] = e^{\frac{1}{2}\left(\frac{t}{\sigma}\right)^2\sigma^2} = e^{\frac{1}{2}t^2} \qquad (3.1.6)$$

Dengan demikian $\frac{\varepsilon_t}{\sigma_t}\left|I_{t-1} \sim N(0,1)\right.$.

Karena runtun waktu $Z_1, Z_2, \ldots, Z_t$ yang didefinisikan oleh $Z_t = \frac{\varepsilon_t}{\sigma_t}$ menjadi berdistribusi identik independen dengan rata-rata nol dan variansi satu maka diperoleh $\varepsilon_t = Z_t \sigma_t$.

3.1.2 Proses Exponential GARCH (p,q)

Misalkan $Z_1, Z_2, \ldots, Z_t$ adalah suatu data runtun waktu; I_t merupakan himpunan informasi yang diketahui pada waktu t. proses Z_t dikatakan mengikuti proses EGARCH (p,q) jika

$\varepsilon_t \left| I_{t-1} \sim N(0, \sigma^2)\right.$ dengan

$$\ln \sigma_t^2 = \omega + \sum_{i=1}^{q} \beta_i \ln \sigma_{t-i}^2 + \sum_{j=1}^{p} \alpha_j \frac{\varepsilon_{t-j}}{\sqrt{\sigma_{t-j}^2}} + \sum_{j=1}^{p} \gamma_j \left[\left|\frac{\varepsilon_{t-j}}{\sqrt{\sigma_{t-j}^2}}\right| - E\left|\frac{\varepsilon_{t-j}}{\sqrt{\sigma_{t-j}^2}}\right|\right]$$

$$= \ln \sigma_t^2 = \omega + \beta_1 \ln \sigma_{t-1}^2 + \ldots + \beta_q \ln \sigma_{t-q}^2 + \alpha_1 \frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}} + \ldots + \alpha_p \frac{\varepsilon_{t-p}}{\sqrt{\sigma_{t-p}^2}} +$$
$$\gamma_1 \left[\left|\frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}}\right| - E\left|\frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}}\right|\right] + \ldots + \gamma_p \left[\left|\frac{\varepsilon_{t-p}}{\sqrt{\sigma_{t-p}^2}}\right| - E\left|\frac{\varepsilon_{t-p}}{\sqrt{\sigma_{t-p}^2}}\right|\right]$$

(3.1.7)

Karena $E\left|\frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}}\right| = 0$ maka persamaan (3.1.6) dapat juga ditulis dalam bentuk

$$\ln\sigma_t^2 = \omega + \sum_{i=1}^{q}\beta_i \ln\sigma_{t-i}^2 + \sum_{j=1}^{p}\alpha_j \frac{\varepsilon_{t-j}}{\sqrt{\sigma_{t-j}^2}} + \sum_{j=1}^{p}\gamma_j\left|\frac{\varepsilon_{t-j}}{\sqrt{\sigma_{t-j}^2}}\right| \tag{3.1.8}$$

3.2 Identifikasi Model

Identifikasi model volatilitas EGARCH melalui beberapa langkah berikut

1. Menentukan model persamaan rata-rata untuk $\{Z_t\}$ menggunakan model ARMA. Langkah-langkah pemodelan telah dibahas pada bab sebelumnya.
2. Dilakukan pengujian efek ARCH terhadap model persamaan rata-rata yang lolos uji verifikasi pada langkah 1.
3. Membentuk model volatilitas *Exponential Generalized Autoregressive Conditional Heteroscedasticity (EGARCH)*. Karena belum terdapat kriteria tertentu untuk mengidentifikasi model volatilitas *Exponential Generalized Autoregressive Conditional Heteroscedasticity (EGARCH*, pada tugas akhir ini penulis akan memodelkan data dengan model volatilitas EGARCH sederhana
4. Menguji efek asimetris dengan melihat korelasi kuadrat standar residual ε_t^2 dengan lag standar residualnya ε_{t-k} Jika nilai korelasi secara signifikan sama dengan nol maka proses runtun waktunya merupakan runtun waktu simetris ARCH/GARCH. Jika korelasi bernilai negatif maka merupakan proses runtun waktu asimetris EGARCH.

3.3 Estimasi Parameter

Dalam pembahasan estimasi parameter EGARCH, misalkan kita mempunyai model regresi

$$y = f(X_t, \beta) + \varepsilon_t , \qquad \text{t = 1,2,..,T dan } \quad \varepsilon_t = X_t \sigma_t^2$$

Jika error dari model regresi di atas mengikuti proses EGARCH maka dengan asumsi normalitas dan didefinisikan I_t sebagai himpunan informasi yang diketahui pada waktu t maka distribusi bersyarat dari errornya adalah

$$\varepsilon_t | I_{t-1} \sim N(0, \sigma_t^2)$$

Dengan fungsi kepadatan peluang

$$fkp = \frac{1}{\sqrt{2\pi\sigma_t^2}} e^{-1/2 \frac{(y - bx_t)^2}{\sigma_t^2}} \qquad (3.3.1)$$

Untuk mengestimasi parameter dari model volatilitas ω, β, α, dan γ pada persamaan (3.1.6) terlebih dahulu akan dicari gradien dari fungsi likelihood pada $\varepsilon_t | I_{t-1} \sim N(0, \sigma_t^2)$

$$f(\varepsilon_t | I_{t-1}) = \frac{1}{\sqrt{2\pi\sigma_t^2}} e^{-1/2 \frac{(y_t - bx_t)^2}{\sigma_t^2}} = \frac{1}{\sqrt{2\pi\sigma_t^2}} e^{-1/2 \frac{\varepsilon_t^2}{\sigma_t^2}} \qquad (3.3.2)$$

Misalkan L_t menyatakan fungsi likelihood untuk observasi ke-t dan ukuran sampel dinyatakan dengan T maka

$$L_t = \prod f(\varepsilon_t | I_{t-1}) = (2\pi)^{-T/2} (\sigma_t^2)^{-T/2} e^{-\frac{1}{2\sigma_t^2} \sum_{t=1}^{T} \varepsilon_t^2}$$

$$\ell_t = \log L$$

$$= -\frac{T}{2}\log 2\pi - \frac{T}{2}\log \sigma_t^2 - \frac{1}{2}\frac{\sum_{t=1}^{T}\varepsilon_t^2}{\sigma_t^2}. \qquad (3.3.3)$$

Untuk mengestimasi parameter ω, β, α, dan γ yang tidak diketahui, fungsi likelihood akan dimaksimumkan. Dalam hal ini parameter-parameter yang tidak diketahui dimuat dalam $\hat{\delta}$. Dengan aturan rantai, turunan pertama untuk fungsi tersebut adalah

$$\frac{\partial \ell_t}{\partial \hat{\delta}} = \frac{\partial \ell_t}{\partial \sigma_t^2}\frac{\partial \sigma_t^2}{\partial \hat{\delta}} = \left[-\frac{T}{2\sigma_t^2} + \frac{1}{2\left(\sigma_t^2\right)^2}\sum_{t=1}^{T}\varepsilon_t^2\right]\frac{\partial \sigma_t^2}{\partial \hat{\delta}}$$

$$= \frac{1}{2\sigma_t^2}\frac{\partial \sigma_t^2}{\partial \hat{\delta}}\left[\frac{\sum_{t=1}^{T}\varepsilon_t^2}{\sigma_t^2} - T\right]. \qquad (3.3.4)$$

Turunan keduanya

$$\frac{\partial^2 \ell_t}{\partial \hat{\delta}\partial \hat{\delta}'} = \frac{\partial}{\partial \hat{\delta}'}\frac{1}{2\sigma_t^2}\frac{\partial \sigma_t^2}{\partial \hat{\delta}}\left[\frac{\sum_{t=1}^{T}\varepsilon_t^t}{\sigma_t^2} - T\right]$$

$$= \frac{1}{2\sigma_t^2}\frac{\partial \sigma_t^2}{\partial \hat{\delta}}\left[-\frac{\sum_{t=1}^{T}\varepsilon_t^2}{\left(\sigma_t^2\right)^2}\frac{\partial \sigma_t^2}{\partial \hat{\delta}'}\right] + \left[\frac{\sum_{t=1}^{T}\varepsilon_t^t}{\sigma_t^2} - T\right]\frac{\partial}{\partial \hat{\delta}'}\left[\frac{1}{2\sigma_t^2}\frac{\partial \sigma_t^2}{\partial \hat{\delta}}\right]$$

$$= -\frac{1}{2\sigma_t^2}\frac{\partial \sigma_t^2}{\partial \hat{\delta}}\frac{\partial \sigma_t^2}{\partial \hat{\delta}'}\left[\frac{\sum_{t=1}^{T}\varepsilon_t^2}{\left(\sigma_t^2\right)^2}\right] + \left[\frac{\sum_{t=1}^{T}\varepsilon_t^2}{\sigma_t^2} - T\right]\frac{\partial}{\partial \hat{\delta}'}\left[\frac{1}{2\sigma_t^2}\frac{\partial \sigma_t^2}{\partial \hat{\delta}}\right]. \qquad (3.3.5)$$

Selanjutnya dicari matriks informasi dari $\hat{\delta}$. Mariks informasi adalah matriks yang elemen-elemennya merupakan negatif dari ekspektasi turunan kedua fungsi likelihoodnya yang berkaitan dengan parameter yang tidak diketahui. Sehingga matriks informasi yang berkaitan dengan $\hat{\delta}$ adalah

$$I_{\hat{\delta}\hat{\delta}'} = -E\left\{\left[\left[-\frac{1}{2\sigma_t^2}\frac{\partial\sigma_t^2}{\partial\hat{\delta}}\frac{\partial\sigma_t^2}{\partial\hat{\delta}'}\left[\frac{\sum_{t=1}^{T}\varepsilon_t^2}{\sigma_t^2\sigma_t^2}\right]\right]\right] + \left[\frac{\sum_{t=1}^{T}\varepsilon_t^2}{\sigma_t^2} - T\right]\frac{\partial}{\partial\hat{\delta}'}\left[\frac{1}{2\sigma_t^2}\frac{\partial\sigma_t^2}{\partial\hat{\delta}}\right]\right\}$$

$$= -\frac{1}{T}\left\{\sum_{t=1}^{T} E\left[-\frac{1}{2\sigma_t^2}\frac{\partial\sigma_t^2}{\partial\hat{\delta}}\frac{\partial\sigma_t^2}{\partial\hat{\delta}'}\frac{\varepsilon_t^2}{\sigma_t^2\sigma_t^2}\right] + \left[\frac{\varepsilon_t^t}{\sigma_t^2} - 1\right]\frac{\partial}{\partial\hat{\delta}'}\left[\frac{1}{2\sigma_t^2}\frac{\partial\sigma_t^2}{\partial\hat{\delta}}\right]\right\}$$

Karena $\varepsilon_t | I_{t-1} \sim N(0, \sigma_t^2)$

$$E(\varepsilon_t^2) = \sigma_t^2$$

Maka $E\left\{\left[\frac{\varepsilon_t^t}{\sigma_t^2} - 1\right]\frac{\partial}{\partial\hat{\delta}'}\left[\frac{1}{2\sigma_t^2}\frac{\partial\sigma_t^2}{\partial\hat{\delta}}\right]\right\} = 0$

Dengan demikian

$$I_{\hat{\delta}\hat{\delta}'} = -\frac{1}{T}\sum_{t=1}^{T} E\left[-\frac{1}{2\sigma_t^2}\frac{\partial\sigma_t^2}{\partial\hat{\delta}}\frac{\partial\sigma_t^2}{\partial\hat{\delta}'}\frac{\varepsilon_t^2}{\sigma_t^2\sigma_t^2}\right]$$

$$= \frac{1}{2T}\sum_{t=1}^{T}\frac{1}{2\sigma_t^2}\frac{\partial\sigma_t^2}{\partial\hat{\delta}}\frac{\partial\sigma_t^2}{\partial\hat{\delta}'}E\left[\frac{\varepsilon_t^2}{\sigma_t^2\sigma_t^2}\right]$$

$$= \frac{1}{2T}\sum_{t=1}^{T}\frac{1}{(\sigma_t^2)^2}\frac{\partial\sigma_t^2}{\partial\hat{\delta}}\frac{\partial\sigma_t^2}{\partial\hat{\delta}'}$$

$$= \frac{1}{2T}\sum_{t=1}^{T}\frac{1}{\sigma_t^4}\frac{\partial\sigma_t^2}{\partial\hat{\delta}}\frac{\partial\sigma_t^2}{\partial\hat{\delta}'}. \qquad (3.3.6)$$

Untuk menemukan pendekatan estimasi parameter maka digunakan metode iteratif. Algoritma optimisasi untuk iterasi dimulai dari suatu nilai awal, misalkan δ_0. Kemudian δ_0 digunakan untuk mencari δ_1. Proses iteratif estimator $\hat{\delta}$

dilakukan sampai diperoleh jarak yang kecil antara $\hat{\delta}_{t-1}$ dan $\hat{\delta}_t$. Metode iteratif yang digunakan adalah metode *Newton-Raphson*, *Method of Scoring*, dan iterasi *Berndt, Hall, Hall & Hausman (BHHH).*

3.3.1 Metode Newton-Raphson

Secara umum metode Newton-Raphson melekukan aproksimasi dengan deret Taylor orde kedua untuk fungsi Likelihood di sekitar nilai awal, yaitu δ_0

$$\ell_t = \ell_t\big|_{\delta_0} + \frac{\partial \ell_t}{\partial \delta'}\bigg|_{\delta_0}(\delta - \delta_0) + \frac{1}{2}(\delta - \delta_0)'\frac{\partial^2 \ell_t}{\partial \delta \partial \delta'}\bigg|_{\delta_0}(\delta - \delta_0) \tag{3.3.7}$$

Untuk memperoleh kondisi optimum, fungsi di atas diturunkan terhadap parameter $\hat{\delta}$

$$\frac{\partial \ell_t}{\partial \delta} = 0 + \left[\frac{\partial \ell_t}{\partial \delta'}\bigg|_{\delta_0}\right] + \frac{\partial^2 \ell_t}{\partial \delta \partial \delta'}\bigg|_{\delta_0}(\delta - \delta_0) = 0 \tag{3.3.8}$$

Berdasarkan persamaan (3.3.6) dan (3.3.7) secara implisit dapat ditaksir δ_1

$$\Rightarrow \frac{\partial \ell_t}{\partial \delta} = \left[\frac{\partial \ell_t}{\partial \delta'}\bigg|_{\delta_1}\right] + \frac{\partial^2 \ell_t}{\partial \delta \partial \delta'}\bigg|_{\delta_1}(\delta_1 - \delta_0) = 0$$

$$\Rightarrow \left[\frac{\partial \ell_t}{\partial \delta'}\bigg|_{\delta_1}\right] = -\frac{\partial^2 \ell_t}{\partial \delta \partial \delta'}\bigg|_{\delta_1}(\delta_1 - \delta_0)$$

$$\Rightarrow \left[\frac{\partial \ell_t}{\partial \delta}\bigg|_{\delta_1}\right] - \left[\frac{\partial^2 \ell_t}{\partial \delta \partial \delta'}\bigg|_{\delta_1}\right]^{-1} = (\delta_1 - \delta_0)$$

$$\Rightarrow \delta_1 = \delta_0 + \left[\frac{\partial \ell_t}{\partial \delta}\bigg|_{\delta_1}\right] - \left[\frac{\partial^2 \ell_t}{\partial \delta \partial \delta'}\bigg|_{\delta_1}\right]^{-1}$$

Bentuk umum menjadi

$$\delta_{n+1} = \delta_n + \left[\left. \frac{\partial \ell_t}{\partial \delta} \right|_{\delta_n} \right] - \left[\left. \frac{\partial^2 \ell_t}{\partial \delta \partial \delta'} \right|_{\delta_n} \right]^{-1} \tag{3.3.9}$$

3.3.2 Method of Scoring

Pada *Method of Scoring*, algoritma iterasi menggunakan nilai ekspektasi dari fungsi *Likelihood*. Algoritmanya dinyatakan sebagai berikut

$$\delta_{n+1} = \delta_n + \left[\left. E\left(\frac{\partial^2 \ell_t}{\partial \delta \partial \delta'} \right) \right|_{\delta_n} \right]^{-1} \left. \frac{\partial \ell_t}{\partial \delta} \right|_{\delta_n} \tag{3.3.10}$$

3.3.2 Iterasi Berndt, Hall, Hall & Hausman (BHHH)

Metode ini mengeksploitasi algoritma iterasi dari *Method of Scoring*. Namun pada iterasi BHHH ditambahkan dengan matriks informasi yang sebelumnya sudah dijelaskan. Bagian yang dieksploitasi adalah matriks simetris atau semi definit positif dari skema iterasi.

Bentuk umum dari skema iterasi BHHH dapat dinyatakan sebagai berikut

$$\delta_{n+1} = \delta_n + \left[-\sum_{t=1}^{T} \left. \frac{\partial^2 \ell_t}{\partial \delta \partial \delta'} \right|_{\delta_n} \right]^{-1} \left. \frac{\partial \ell_t}{\partial \delta} \right|_{\delta_n} \tag{3.3.11}$$

3.4 Verifikasi Model

Seperti halnya verifikasi pada model persamaan rata-rata, pada model volatilitas verifikasi bertujuan untuk memeriksa apakah model yang dibentuk cukup cocok dengan data yang ada. Pengujian yang dapat dilakukan terdapat dua jenis, yaitu berdasarkan keberartian koefisien dan nilai AIC/SIC.

3.4.1 Pengujian Berdasarkan Keberartian Koefisien

Langkah pengujian keberartian koefisien pada model volatilitas tidak berbeda dengan pengujian pada model persamaan rata-rata ARMA.

3.4.2 Pengujian Berdasarkan Perbandingan Nilai AIC dan SIC

Model terbaik dapat dipilih berdasarkan nilai *Akaike Information Criterion* (AIC) dan *Schwarz Information Criterion* (SIC). Model terbaik adalah model yang memiliki nilai *Akaike Information Criterion* (AIC) dan *Schwarz Information Criterion* (SIC) paling kecil. AIC dan SIC didefinisikan sebagai berikut (Widarjono, 2005)

$$\text{AIC} = \ln\left(\frac{RSS}{n}\right) + \frac{2k}{n} \tag{3.4.1}$$

$$\text{SIC} = \ln\left(\frac{RSS}{n}\right) + \frac{k}{n}\ln n \tag{3.4.2}$$

Dengan RSS = Jumlah residual kuadrat (*Residual sum of squares*)

n = Jumlah observasi

k = Jumlah parameter yang di estimasi