

Analisis Model *Threshold Generalized Autoregressive Conditional Heteroskedasticity* (TGARCH) dan Model *Exponential Generalized Autoregressive Conditional Heteroskedasticity* (EGARCH) (Studi Kasus: Indeks Harga Saham Gabungan (IHSG) pada Januari 2011 sampai dengan Juni 2017)

Analysis The Model of Threshold Generalized Autoregressive Conditional Heteroskedasticity (TGARCH) and Exponential Generalized Autoregressive Conditional Heteroskedasticity (EGARCH) (Case Study: Indonesia Composite Index (ICI) from January 2011 to June 2017)

Julia¹, Sri Wahyuningsih², dan Memi Nor Hayati³

¹Laboratorium Statistika Ekonomi dan Bisnis Jurusan Matematika FMIPA Universitas Mulawarman

^{2,3}Laboratorium Statistika Terapan Jurusan Matematika FMIPA Universitas Mulawarman

E-mail: julia12des95@gmail.com

Abstract

In the field of finance, Autoregressive Integrated Moving Average (ARIMA) is one of the models that can be used. Financial data usually have a non constant variance error. Thus, Autoregressive Conditional Heteroskedasticity (ARCH) model can be used to solve the problem. In addition, it also can be used the development of ARCH model that is Generalized Autoregressive Conditional Heteroskedasticity (GARCH) model. The symmetry of residual data can be determined by using the model of Threshold Generalized Autoregressive Conditional Heteroskedasticity (TGARCH) and the model of Exponential Generalized Autoregressive Conditional Heteroskedasticity (EGARCH). The purpose of this research is to know the best model among the model of TGARCH and the model of EGARCH in predicting Indonesia Composite Index (ICI) and the results of ICI forecasting by using the best model for the period of July 2017 until December 2017. The best model in the ICI case study from January 2011 to June 2017 is the model of ARIMA (1,1,1) - GARCH (1,2) -EGARCH (1). The results of ICI forecasting by using the model of ARIMA (1,1,1) -GARCH (1,2) -EGARCH (1) obtained an upward trend in the period of July 2017 to December 2017.

Keywords: ARIMA, EGARCH, GARCH, ICI, TGARCH.

PENDAHULUAN

Saat ini ilmu ekonometrika banyak digunakan untuk meramalkan kondisi pasar modal. Berbagai model statistik, grafik, *software computer*, dan indikator teknikal lainnya diperjual-belikan atau disediakan pada *website-website* besar seperti *Yahoo*, *Google*, *Blomberg*, *Kontan Online*, *Meta Stok*, dan lain sebagainya (Dzikevicius & Sarana, 2010). *Autoregressive Integrated Moving Average* (ARIMA) merupakan tipe model peramalan dalam bidang keuangan (Wilson & Keating, 2007). Zhang (2003) menyatakan bahwa ARIMA tidak mampu memodelkan *time series* yang non-linear. Aspek-aspek AR dan MA dari model ARIMA hanya berkenaan dengan deret berkala yang stasioner.

Bollerslev (1986) menggeneralisasi model ARCH dengan mencakup nilai lag dari variansi bersyarat yang terkenal dengan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH). Keberadaan efek *leverage* pada data finansial menyebabkan model GARCH menjadi tidak tepat digunakan untuk menduga model (Ariefianto, 2012).

Pengembangan model GARCH yang selanjutnya mengakomodasi kemungkinan adanya

respon volatilitas yang asimetris. Ada dua teknik pemodelan respon GARCH asimetris, yakni model *Threshold GARCH* oleh Glosten, et al (1993) dan *Exponential GARCH* (EGARCH) dari Nelson (1991).

Pengaruh efek *leverage* yaitu volatilitas meningkat lebih setelah penurunan dari pada setelah kenaikan dalam jumlah yang sama dapat diketahui dengan menggunakan model asimetris berupa model *Threshold GARCH*.

EGARCH diajukan Nelson pada tahun 1991 untuk menutupi kelemahan model ARCH/GARCH dalam menangkap fenomena asimetris *good news* dan *bad news* dalam volatilitas. Keadaan yang disebut efek *leverage* ini ditangkap oleh model *Exponential GARCH*.

Prihandini (2015) melakukan penelitian mengenai Penerapan Model EGARCH Pada Estimasi Volatilitas Harga Minyak Kelapa Sawit, hasil yang diperoleh yaitu model terbaik untuk Harga Minyak Kelapa Sawit adalah EGARCH(1,1).

Penelitian ini dibatasi pada penerapan analisis model TGARCH dan model EGARCH pada studi kasus IHSG pada Januari 2011 sampai dengan Juni 2017. Di mana pada analisis ACF dan

PACF hanya membatasi pada pemotongan lag 5, karena keterbatasan peneliti. Adapun tujuan dari penelitian ini yaitu untuk mengetahui model yang manakah terbaik di antara model TGARCH dan model EGARCH dalam meramalkan nilai IHSG serta mengetahui hasil peramalan nilai IHSG dengan menggunakan model yang terbaik untuk 6 bulan ke depan.

Deret Waktu

Deret waktu (*time series*) merupakan serangkaian data pengamatan yang terjadi berdasarkan indeks waktu secara berurutan dengan interval waktu tetap. Analisis deret waktu adalah salah satu prosedur statistika yang diterapkan untuk meramalkan struktur probabilistik keadaan yang akan terjadi di masa yang akan datang dalam rangka pengambilan keputusan.

Stasioneritas

Sesuatu data *time series* dikatakan stasioner dalam variansi apabila struktur data dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah. Secara visual untuk melihat hal tersebut dapat dibantu dengan menggunakan *plot time series*, yaitu dengan melihat fluktuasi data dari waktu ke waktu.

Stasioner dalam rata-rata adalah fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan variansi dari fluktuasi tersebut. Dari bentuk *plot* data seringkali dapat diketahui bahwa data tersebut stasioner atau tidak stasioner. Apabila data tidak stasioner, maka perlu dilakukan transformasi untuk menghasilkan data yang stasioner (Makridakis, et al, 1995).

Transformasi Box Cox

Bila kondisi stasioner dalam variansi tidak diperoleh, Box & Cox (1964) dalam buku Wei (2006) memperkenalkan transformasi pangkat (*power transformation*),

$$Z_t^{(\lambda)} = \begin{cases} \frac{Z_t^{(\lambda)} - 1}{\lambda}, \lambda \neq 0 \\ \ln(Z_t), \lambda = 0 \end{cases} \quad (1)$$

(Aswi & Sukarna, 2006)

Transformasi Differencing

Tujuan dari transformasi ini adalah membentuk barisan data runtun waktu yang bersifat stasioner, yakni untuk mencari komponen stasioner dari data yang memuat komponen *trend* dan komponen musiman. *Differencing* orde 1 dari suatu data runtun waktu Z_t dengan persamaan:

$$(1 - B)^d Z_t = a_t \quad (2)$$

Di mana

$$B^d Z_t = Z_{t-d} \quad (3)$$

Keterangan

$d = differencing$ orde ke- d

(Wei, 2006)

Uji ADF (*Augmented Dickey Fuller*)

Uji ini merupakan salah satu uji yang paling sering digunakan dalam pengujian stasioneritas Rumusan hipotesis untuk uji ADF adalah:

$$H_0 : \gamma = 0 \text{ (tidak stasioner)}$$

$$H_1 : \gamma \neq 0 \text{ (stasioner)}$$

Prosedur untuk menentukan apakah data stasioner atau tidak dengan cara membandingkan antara nilai statistik uji t yang disimbolkan dengan τ yaitu:

$$\tau = \left| \frac{\hat{\gamma}}{SE(\hat{\gamma})} \right| \quad (4)$$

di mana $\hat{\gamma}$ adalah nilai taksiran dari parameter, $SE(\hat{\gamma})$ merupakan standar *error* dari nilai taksiran $\hat{\gamma}$, dengan daerah kritis pengujian ini adalah menolak H_0 apabila nilai statistik ADF atau τ lebih besar dari pada absolut nilai kritis distribusi statistik t yaitu $|t_{(\frac{\alpha}{2}; df=n-n_p)}|$, di mana n adalah

banyak pengamatan dan n_p adalah jumlah parameter (Gujarati, 2003).

Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

Menurut Makridakis (1995), fungsi ACF dan fungsi PACF merupakan alat untuk mengidentifikasi model dari suatu data *time series* yang akan diramalkan, autokorelasi untuk *time lag* 1, 2, 3, ..., k dapat ditulis:

$$\rho_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, \quad (5)$$

Nilai fungsi autokorelasi parsial lag k hasilnya dinyatakan dalam Persamaan 6. ϕ_{kk} disebut PACF antara Z_t dan Z_{t+k} . Himpunan dari $\phi_{kk}, \{\phi_{kk}; k = 1, 2, \dots\}$ disebut sebagai

PACF. Fungsi ϕ_{kk} menjadi notasi standar untuk Autokorelasi parsial antara observasi Z_t dan Z_{t+k} dalam analisis *time series* (Wei, 2006).

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \rho_2 & \rho_1 & 1 & \dots & \rho_{k-4} & \rho_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & \dots & \rho_{k-4} & \rho_{k-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & 1 \end{vmatrix}} \quad (6)$$

Hipotesis untuk menguji koefisien autokorelasi parsial adalah $H_0 : \phi_{kk} = 0$ (tidak terdapat autokorelasi parsial)

$$H_1 : \phi_{kk} \neq 0 \text{ (terdapat autokorelasi parsial)}$$

Taraf signifikansi

α
Statistik uji

$$t_{\phi_{kk}} = \frac{\phi_{kk}}{S_{\phi_{kk}}} \quad (7)$$

Dengan

$$S_{\phi_{kk}} = \sqrt{\frac{1}{n}} \quad (8)$$

Kreteria keputusan: tolak H_0 jika $t_{hitung} > t_{\frac{\alpha}{2}, df}$, dengan derajat bebas $df = n - 1$, n adalah banyaknya data dan k adalah lag koefisien autokorelasi parsial yang akan diuji (Aswi & Sukarna, 2006).

Model Autoregressive

Pembahasan pertama model ARIMA akan dimulai dari model autoregresif (*Autoregressive* = AR). Persamaan model AR(p) dapat ditulis sebagai berikut:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t = a_t$$

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (9)$$

$$Z_t = \phi_0 + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (10)$$

di mana: Z_t = variabel dependen; Z_{t-1} = lag dari Z . Dan: Z = variabel dependen; $Z_{t-1}, Z_{t-2}, Z_{t-p}$ = lag dari Z ; p = tingkat AR; a_t = residual (kesalahan pengganggu);

Model Moving Average

Model kedua ARIMA adalah model *Moving Average* (MA). Model MA(q) dapat ditulis dalam bentuk persamaan sebagai berikut:

$$Z_t = (1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (11)$$

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

$$Z_t = \phi_0 + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (12)$$

Di mana: q = tingkat MA.

Model Autoregressive-Moving Average

Model gabungan ini disebut *Autoregressive-Moving Average* (ARMA). Secara umum bentuk model dari ARMA dapat ditulis dalam bentuk persamaan sebagaimana berikut:

$$(1 - \phi_1 B^1 - \phi_2 B^2 - \dots - \phi_p B^p) Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t$$

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1}$$

$$- \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

$$Z_t = \phi_0 + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1}$$

$$- \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

$$(13)$$

Model Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA (p, d, q) dimana p adalah tingkat AR, d tingkat proses membuat data menjadi stasioner dan q merupakan tingkat MA.

Model ARIMA(p, d, q) dapat ditulis dalam bentuk persamaan sebagai berikut:

$$(1 - B)^d (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (14)$$

Berdasarkan Persamaan (14) model ARIMA(1,1,1) dapat dinyatakan sebagai berikut:

$$Z_t = \phi_0 + (1 + \phi_1) Z_{t-1} - \phi_1 Z_{t-2} + a_t - \theta_1 a_{t-1} \quad (15)$$

(Widarjono, 2013)

Uji Stasioner Melalui Correlogram

Sebelum membahas secara detail model ARIMA, pada sub bab ini akan dibahas metode

deteksi masalah stasioneritas data yang digunakan. Metode sederhana yang dapat digunakan untuk menguji apakah data stasioner atau tidak dengan melihat *correlogram* melalui *Autocorrelation Function* (ACF). ACF menjelaskan seberapa besar korelasi data yang berurutan dalam runtun waktu. ACF dengan demikian adalah perbandingan antara kovarian pada kelambanan k dengan variannya. Dengan demikian ACF pada lag $k(\rho_k)$ dapat ditulis sebagai berikut:

$$\rho_k = \frac{\gamma_k}{\gamma_0} \tag{16}$$

di mana:

$$\gamma_k = \frac{\sum (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}_{t+k})}{n} \tag{17}$$

$$\gamma_k = \frac{\sum (Z_t - \bar{Z})^2}{n} \tag{18}$$

n adalah jumlah observasi dan \bar{Z} adalah rata-rata. Nilai ACF ini akan terletak pada -1 dan 1. Persamaan (19) merupakan ACF untuk populasi sehingga kita perlu melakukan estimasi ACF melalui *Sample Autocorrelation Function* (SACF). SACF pada data ke- k dengan demikian dapat ditulis sebagai berikut:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} \tag{19}$$

Alternatif lain uji stasioner berdasarkan nilai koefisien SACF dikembangkan oleh Ljung-Box dikenal dengan uji statistik Ljung-Box (LB). Adapun formula uji LB sebagai berikut:

$$LB = n(n+2) \sum_{k=1}^m \left(\frac{\hat{\rho}_k^2}{n-k} \right) \chi_m^2 \tag{20}$$

untuk sampel besar, uji statistik LB ini sebagaimana uji statistik Q mengikuti distribusi *chi squares* χ^2 dengan derajat kebebasan (df) sebesar m . Jika nilai statistik LB lebih kecil dari nilai kritis statistik dari tabel distribusi *chi squares* χ^2 maka data menunjukkan stasioner. Sebaliknya jika nilai statistik LB lebih besar dari nilai kritis statistik dari tabel distribusi *chi squares* χ^2 maka data tidak stasioner (Wei, 2006).

Identifikasi Model

Menurut Gujarati (2003), jika koefisien ACF menurun dratis pada kelambanan tertentu sedangkan PACF menurun secara eksponensial maka model yang tepat adalah MA. Namun, bila koefisien ACF maupun PACF menurun secara eksponensial maka model yang tepat adalah ARMA.

Uji Signifikansi Parameter

Uji signifikansi parameter di mana misalkan θ adalah suatu parameter pada model ARIMA Box-Jenkins, $\hat{\theta}$ adalah nilai taksiran dari parameter tersebut, serta $SE(\hat{\theta})$ adalah standar *error* dari nilai taksiran $\hat{\theta}$, maka dapat dilakukan dengan tahapan sebagai berikut:

Hipotesis

$$H_0 : \theta = 0$$

$$H_0 : \theta \neq 0$$

Statistik Uji

$$t = \frac{\hat{\theta}}{SE(\hat{\theta})} \tag{21}$$

Daerah Penolakan

$$\text{Menolak } H_0 \text{ jika } |t| > t_{\alpha/2; df=n-n_p},$$

n_p = banyaknya parameter atau dengan menggunakan *p-value* (*probability*), yakni menolak H_0 jika *probability* < α .

Uji Kesesuaian Model

Asumsi residual bersifat *white noise* model dapat ditulis sebagai berikut.

1. Hipotesis

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \text{ (Model sudah memenuhi syarat cukup).}$$

$$H_1 : \text{Minimal ada satu}$$

$$\rho_j \neq 0, j = 0, 1, 2, \dots, k \text{ (Model belum memenuhi syarat cukup).}$$

2. Statistik uji, yaitu statistik uji *Ljung-Box* atau *Box-Pierce Modified*:

$$Q^* = n(n+2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{(n-k)} \tag{22}$$

di mana $\hat{\rho}_k$ diperoleh dari

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (\hat{a}_t - \bar{a})(\hat{a}_{t+k} - \bar{a})}{\sum_{t=1}^n (\hat{a}_t - \bar{a})^2} \tag{23}$$

Daerah penolakan:

$$\text{Menolak } H_0 \text{ jika } Q^* > \chi_{\alpha; df=k-m}^2. k \text{ berarti pada lag } k \text{ dan } m \text{ adalah jumlah parameter yang ditaksir dalam model (Aswi \& Sukarna, 2006).}$$

Uji asumsi residual berdistribusi normal ini bertujuan untuk mengetahui apakah data telah memenuhi asumsi kenormalan atau belum.

Selain itu uji kenormalan lainnya seperti Jarque Bera, uji Jarque Bera adalah salah satu metode untuk menguji kenormalan data. Uji Jarque Bera ini dapat dinyatakan sebagai:

$$JB = \frac{n}{6} \left(S^2 + \frac{(K-3)^2}{4} \right) \quad (24)$$

Dengan

$$S = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{3/2}}$$

dan

$$K = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^2}$$

Keterangan:

- x = data yang akan diuji kenormalan
- n = ukuran sampel
- S = skewness
- K = kurtosis

Uji Jarque Bera mempunyai distribusi chi-kuadrat dengan derajat bebas dua ($\chi^2_{;2}$). Jika hasil Jarque Bera lebih besar dari distribusi chi-kuadrat maka H_0 ditolak yang berarti data tidak berdistribusi normal atau $p\text{-value} \leq \alpha$ dan jika sebaliknya maka berdistribusi normal (Kabasarang, et al, 2016).

Pemilihan Model Terbaik

AIC adalah suatu kriteria pemilihan model terbaik yang diperkenalkan oleh Akaike pada tahun 1973 dengan mempertimbangkan banyaknya parameter dalam model. Kriteria AIC dapat dirumuskan sebagai berikut:

$$AIC = n \times \ln(SSE / n) + 2f + n + n \times \ln(2\pi) \quad (25)$$

dengan:

- ln = natural log
- SSE = sum square error
- n = banyaknya pengamatan
- f = banyaknya parameter dalam model
- π = 3,14

Semakin kecil nilai AIC yang diperoleh berarti semakin baik model yang digunakan (Hanke, et al, 2005).

Model GARCH

Model ARCH dari Robert Engle ini kemudian disempurnakan oleh Tim Bollerslev. Jika kita memasukkan juga variansi residual periode lalu maka model ini dikenal dengan *Generalized Autoregressive Conditional*

Heterkadasticity (GARCH). Untuk menjelaskan model GARCH ini kita kembali menggunakan model regresi sederhana sebagai berikut:

$$Y_t = \beta_0 + \beta_1 Z_t + a_t \quad (26)$$

dimana: Y = variabel dependen; Z = variabel independen; a = residual;

Secara umum model GARCH yakni GARCH (p, q) dapat dinyatakan melalui persamaan sebagai berikut:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \sigma_{t-1}^2 + \dots + \alpha_p \sigma_{t-p}^2 + \lambda_1 \sigma_{t-1}^2 + \dots + \lambda_q \sigma_{t-q}^2 \quad (27)$$

Dimana p menunjukkan unsur ARCH dan q unsur GARCH.

Model TGARCH

Pembahasan ARCH/GARCH sebelumnya berangkat dari asumsi bahwa terdapat gejala yang bersifat simetris terhadap volatilitas (*symmetric shocks to volatility*).

Ada dua model yang mengakomodasi gejala asimetris ini yaitu model TGARCH dan EGARCH.

Sedangkan spesifikasi untuk varian (*conditional variance*) sebagai berikut:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \sigma_{t-1}^2 + \dots + \alpha_p \sigma_{t-p}^2 + \phi e_{t-1} d_{t-1} + \lambda_1 \sigma_{t-1}^2 + \dots + \lambda_q \sigma_{t-q}^2 \quad (28)$$

Di dalam model TGARCH ini, berita baik (*good news*) pada periode $t-1$ ($a_{t-1} < 0$) dan berita buruk (*bad news*) pada periode $t-1$ ($a_{t-1} > 0$) mempunyai efek yang berbeda terhadap *conditional varian*. Berita baik mempunyai dampak terhadap α dan berita buruk mempunyai dampak terhadap $\alpha + \phi$. Jika $\phi \neq 0$ maka terjadi efek asimetris.

Model EGARCH

EGARCH merupakan eksponensial GARCH. EGARCH sebagaimana TGARCH juga mengakomodasi adanya gejala asimetris tersebut.

Maka spesifikasi untuk *conditional variance* sebagai berikut:


$$\ln \sigma_t^2 = \sigma^2 + \alpha_1 \left| \frac{a_{t-1}}{\sigma_{t-1}} \right| + \phi_1 \frac{a_{t-1}}{\sigma_{t-1}} + \dots + \alpha_p \left| \frac{a_{t-p}}{\sigma_{t-p}} \right| + \phi_p \frac{a_{t-p}}{\sigma_{t-p}} + \lambda_1 \ln \sigma_{t-1}^2 + \dots + \lambda_q \sigma_{t-q}^2 \quad (29)$$

Pemakaian bentuk \ln pada persamaan *conditional variance* menunjukkan bahwa *conditional* bersifat eksponensial bukan dalam bentuk kuadratik seperti persamaan *conditional variance* didalam model ARCH/GARCH maupun TGARCH. Selain itu penggunaan \ln juga menjamin bahwa varian tidak pernah negatif. Efek asimetris terjadi jika $\phi \neq 0$ (Widarjono, 2013).

Hasil dan Pembahasan

Data IHSG yang digunakan pada penelitian ini adalah dari Januari 2011 sampai dengan Juni 2017, dengan jumlah observasi 78 bulan. Berdasarkan grafik runtun waktu dapat diketahui stasioner dalam variansi maupun rata-rata data IHSG.


Time Series Plot



Gambar 1 Grafik IHSG


Pada Gambar 1 data IHSG yang terendah pada bulan Januari tahun 2011 dan selanjutnya mengalami kenaikan dan penurunan secara fluktuatif. Data IHSG bulan Januari 2011 sampai dengan Juni 2017 ini mengalami *trend* naik atau *uptrend*. Jadi data IHSG tersebut tidak stasioner dalam variansi maupun rata-rata sehingga perlu dilakukan Box-Cox *plot* pada data untuk variansi dan Uji ADF pada data untuk rata-rata.

Box-Cox Plot



Gambar 2 Grafik Box Cox IHSG

Pada Gambar 2 nilai estimasi $\lambda = 1,210$, karena nilai estimasi λ melebihi 1, maka dapat disimpulkan bahwa data IHSG tidak stasioner dalam variansi, sehingga perlu dilakukan transformasi. Transformasi yang digunakan adalah $Z_t^{1,210}$ yang hasilnya dinotasikan dengan Z_t^* . Setelah dilakukan transformasi diperoleh nilai estimasi $\lambda = 1$.




Gambar 3. Grafik transformasi Box Cox.

Pada Gambar 3 nilai estimasi $\lambda = 1$, maka dapat disimpulkan bahwa Z_t^* telah stasioner dalam variansi. Selanjutnya akan dilakukan Uji ADF untuk mengetahui apakah data Z_t^* sudah stasioner dalam rata-rata.

Uji ADF

Setelah data stasioner dalam variansi, dilakukan Uji ADF untuk mengetahui stasioner dalam rata-rata. Didapatkan nilai $\tau = 1,891 < t_{(0,1;77)} = 1,991$, maka diputuskan gagal menolak H_0 dan disimpulkan bahwa data Z_t^* tidak stasioner. Karena data Z_t^* belum stasioner, selanjutnya dilakukan *differencing* dengan $d = 1$. Didapatkan nilai $\tau = 7,790 > t_{(0,1;76)} = 1,992$, maka diputuskan menolak H_0 . Dapat disimpulkan bahwa data Z_t^* setelah dilakukan *differencing* orde 1 sudah stasioner.



Gambar 4. Grafik Z_t^* setelah dilakukan *differencing* orde 1

Pada Gambar 4 data Z_t^* setelah dilakukan *differencing* orde 1 sudah stasioner dalam variansi maupun dalam rata-rata.

Identifikasi Model

Identifikasi model AR dan MA dari suatu *time series* dilakukan dengan melihat *Correlogram* yang merupakan grafik yang menunjukkan nilai ACF di lag 22 dan PACF 18.

Estimasi Parameter Model ARIMA

Setelah identifikasi model, langkah selanjutnya adalah estimasi model ARIMA atau Estimasi parameter dari model-model yang signifikan pada Tabel 1.

Tabel 1. Estimasi Parameter Model ARIMA

Model	Estimasi Parameter	Prob.
ARIMA(1,1,1)	$\phi_0 = 162,628$	0,031
	$\phi_1 = -0,825$	0,000
	$\theta_1 = 0,974$	0,000
ARIMA(3,1,3)	$\phi_0 = 143,502$	0,039
	$\phi_1 = -1,863$	0,000
	$\phi_2 = -1,697$	0,000
	$\phi_3 = -0,674$	0,000
	$\theta_1 = 2,062$	0,000
	$\theta_2 = 1,989$	0,000
	$\theta_3 = 0,885$	0,000

Uji Signifikansi Parameter

Untuk mengetahui model terbaik, maka perlu dilakukan pengujian signifikansi parameter untuk ke-35 model pada Tabel 4 menunjukkan hasil estimasi parameter model dugaan sementara dan nilai *probability* (*p-value*) untuk pengujian signifikansi parameter. Sebagai contoh pengujian signifikansi parameter untuk model ARIMA(1,1,1) adalah sebagai berikut:

Berdasarkan Tabel 1 *probability* parameter ϕ_0, ϕ_1, θ_1 semuanya bernilai $< \alpha = 0,100$, maka diputuskan H_0 ditolak dan disimpulkan bahwa $\phi_0, \phi_1, \theta_1 = 0$, yaitu parameter model ARIMA(1,1,1) tidak signifikan. Berdasarkan pengujian signifikansi parameter diperoleh kesimpulan bahwa model yang memiliki parameter yang signifikan untuk data Z_t^* setelah dilakukan *differencing* orde 1 adalah ARIMA(1,1,1) dan ARIMA(3,1,3).

Uji Kesesuaian Model

Setelah model yang signifikan didapat maka dilanjutkan uji kesesuaian model pada data residual model ARIMA(1,1,1) dan model ARIMA(3,1,3) sebagai berikut:

Tabel 2. Uji White noise

Model	Probability		
	Lag 7	Lag 8	Lag 13
ARIMA(1,1,1)	0,770	0,961	0,947
ARIMA(3,1,3)	0,233	0,487	0,669

Pada Tabel 2 nilai *probability* pada lag 7, lag 8 dan lag 13 pada model ARIMA(1,1,1) dan ARIMA(3,1,3) memiliki nilai *probability* $> \alpha = 0,100$ diputuskan bahwa H_0 gagal ditolak

sehingga dapat disimpulkan bahwa model residual bersifat *white noise*.

Pengujian kenormalan residual model ARIMA(1,1,1) dan model ARIMA(3,1,3).

Tabel 3. Uji Kenormalan Residual

Model	Probability
ARIMA(1,1,1)	4,146
ARIMA(3,1,3)	0,126

Pada Tabel 3 model ARIMA(1,1,1) dan model ARIMA(3,1,3) memiliki nilai *probability* $> \alpha = 0,100$ maka diputuskan H_0 gagal ditolak, maka disimpulkan residual berdistribusi normal.

Pemilihan Model ARIMA Terbaik

Pada Tabel 1 dan Tabel 2 model ARIMA(1,1,1) dan model ARIMA(3,1,3) yang memenuhi asumsi *white noise* dan residual berdistribusi normal, maka model ARIMA(1,1,1) dan model ARIMA(3,1,3) dilihat nilai AIC terkecil.

Tabel 4. AIC

Model	AIC
ARIMA(1,1,1)	17,180
ARIMA(3,1,3)	17,193

Pada Tabel 4 dapat dilihat nilai AIC terkecil yaitu model ARIMA(1,1,1), setelah dapat dilanjutkan dengan uji asumsi heteroskedastisitas (efek ARCH) pada model. Dengan Persamaan (15) model:

$$Z_t = 162,628 + (1 - 0,825)Z_{t-1} + (0,825)Z_{t-2} + a_t - 0,974a_{t-1}$$

$$Z_t = 162,628 + 0,175Z_{t-1} + 0,825Z_{t-2} + a_t - 0,974a_{t-1}$$

Uji Asumsi Heteroskedastisitas (Efek ARCH)

Tabel 5. Uji ARCH-Lagrange Multiplier

<i>Obs* R-squared</i>	7,564
<i>Probability</i>	0,006

Pada Tabel 5 nilai *probability* = 0,006 $< \alpha = 0,100$, diputuskan menolak H_0 , maka dapat disimpulkan bahwa terdapat heteroskedastisitas pada data. Dengan demikian pemodelan dilanjutkan dengan menggunakan model GARCH.

GARCH

Identifikasi model GARCH pada penelitian ini sampai orde 3, karena pada model GARCH orde maksimum adalah orde 3. Jika sampai orde 3 didapatkan model terbaik maka dari model

GARCH sendiri bisa dilanjutkan ke pemodelan TGARCH dan EGARCH.

Estimasi Parameter GARCH

Setelah diuji heteroskedastisitas model ARIMA(1,1,1) digabungkan menjadi model GARCH, Estimasi parameter dari model yang signifikan pada Tabel 6.

Tabel 6. Estimasi Parameter Model GARCH

Model	Estimasi Parameter	Prob.
ARIMA(1,1,1)-GARCH(1,2)	$\phi_0 = 470,665$	0,004
	$\phi_1 = -0,615$	0,000
	$\theta_1 = 0,933$	0,000
	$\alpha_1 = 1076125$	0,000
	$\alpha_0 = 0,189$	0,001
	$\lambda_1 = 1,095$	0,000
	$\lambda_2 = -0,829$	0,000

Uji Signifikansi Parameter

Untuk mengetahui model terbaik, maka perlu dilakukan pengujian signifikansi parameter untuk ke-15 model pada Tabel 6 menunjukkan hasil estimasi parameter model dugaan sementara dan nilai *probability* untuk pengujian signifikansi parameter. Pengujian signifikansi parameter untuk model ARIMA(1,1,1)-GARCH(1,2) adalah sebagai berikut:

Karena nilai *probability* pada Tabel 9 $< \alpha = 0,100$, maka diputuskan menolak H_0 . Disimpulkan bahwa model ARIMA(0,0,2)-GARCH(2,1) signifikan. Berdasarkan pengujian signifikan parameter diperoleh kesimpulan bahwa model yang signifikan untuk data Z_t^* setelah dilakukan *differencing* orde 1 adalah ARIMA(1,1,1)-GARCH(1,2). Setelah model ARIMA(1,1,1)-GARCH(1,2) signifikan dilanjutkan uji kesesuaian model.

Uji Kesesuaian Model

Setelah model ARIMA(1,1,1)-GARCH(1,2) signifikan, lanjutkan ke residual *white noise* dan residual berdistribusi normal.

Tabel 7. Uji White noise

Model	Probability		
	Lag 7	Lag 8	Lag 13
ARIMA(1,1,1)-GARCH(1,2)	0,431	0,555	0,626

Pada Tabel 7 ARIMA(1,1,1)-GARCH(1,2) memiliki *probability* $> \alpha = 0,100$ diputuskan bahwa gagal menolak H_0 , sehingga dapat

disimpulkan model residual *white noise*. Setelah *white noise* dilanjutkan uji distribusi normal.

Pengujian kenormalan residual Model ARIMA(1,1,1)-GARCH(1,2) sebagai berikut:

Tabel 8. Uji Kenormalan Residual

Model	Probability
ARIMA(1,1,1)-GARCH(1,2)	0,172

Pada Tabel 8 nilai *probability* $> \alpha = 0,100$ maka diputuskan gagal menolak H_0 , dan disimpulkan residual berdistribusi normal.

Pemilihan Model Terbaik

Pada Tabel 7 dan Tabel 8 model ARIMA(1,1,1)-GARCH(1,2) yang memenuhi asumsi *white noise* dan residual berdistribusi normal, maka model ARIMA(1,1,1)-GARCH(1,2) adalah model terbaik dan dilanjutkan dengan uji asumsi efek ARCH menggunakan ARCH-LM. Berdasarkan Persamaan (27) maka model terbaik ARIMA(1,1,1)-GARCH(1,2) sebagai berikut:

$$Z_t = 470,665 + 0,385Z_{t-1} + 0,615Z_{t-2} + a_t - 0,933a_{t-1}$$

$$\sigma_t^2 = 1076125 + 0,189\sigma_{t-1}^2 + 1,0946\sigma_{t-1}^2 - 0,829\sigma_{t-2}^2$$

ARCH-LM

Uji heteroskedastisitas menggunakan ARCH-LM dan pada Tabel 9.

Tabel 9. Uji ARCH-Lagrange Multiplier

F-statistic	Probability
0,122	0,728

Pada Tabel 9 nilai *probability* $= 0,728 > \alpha = 0,100$, diputuskan gagal menolak H_0 , maka dapat disimpulkan bahwa tidak terdapat efek ARCH pada data. Setelah tidak ada efek ARCH maka pemodelan bisa di lanjutkan dengan TGARCH dan EGARCH.

TGARCH

Identifikasi model TGARCH pada penelitian ini sampai orde 1, karena pada model ARIMA(1,1,1)-GARCH(1,2) yang di mana nilai TGARCH itu sendiri berasal dari nilai residual ARCH(1).

Estimasi Parameter TGARCH

Tabel 10. Estimasi Model TGARCH

Model	Estimasi Parameter	Prob.
ARIMA(1,1,1)- GARCH(1,2)- TGARCH(1)	$\phi_0 = 253,975$	0,089
	$\phi_1 = -0,739$	0,000
	$\theta_1 = 0,961$	0,000
	$\alpha_1 = 1076223$	0,000
	$\alpha_0 = -0,089$	0,745
	$\lambda_1 = 0,410$	0,207
	$\lambda_2 = 0,992$	0,000
	$\phi = -0,684$	0,000

Uji Signifikansi Parameter

Untuk mengetahui model TGARCH(1) bisa digunakan, maka perlu dilakukan pengujian signifikansi parameter model ARIMA(1,1,1)-GARCH(1,2)-TGARCH(1) pada Tabel 13 menunjukkan hasil estimasi parameter model dugaan sementara dan nilai *probability* untuk pengujian signifikansi parameter. Sebagaimana pengujian signifikansi parameter untuk model ARIMA(1,1,1)-GARCH(1,2)-TGARCH(1) adalah sebagai berikut:

Keputusan dan Kesimpulan

Karena nilai *probability* pada Tabel 10 > $\alpha = 0,100$, maka diputuskan gagal menolak H_0 . Disimpulkan bahwa parameter model TGARCH(1) tidak signifikan. Jadi model tidak bisa digunakan karena ada yang tidak signifikan.

EGARCH

Estimasi Parameter EGARCH

Tabel 11. Estimasi Model EGARCH

Model	Estimasi Parameter	Prob.
ARIMA(1,1,1)- GARCH(1,2)- EGARCH(1)	$\phi_0 = 214,148$	0,061
	$\phi_1 = -0,862$	0,000
	$\theta_1 = 0,968$	0,000
	$\alpha_1 = 8,693$	0,000
	$\alpha_0 = -0,485$	0,000
	$\lambda_1 = -0,474$	0,010
	$\lambda_2 = 1,281$	0,011
	$\phi = -0,871$	0,000

Identifikasi model EGARCH pada penelitian ini sampai orde 1, karena pada model ARIMA(1,1,1)-GARCH(1,2) ada model ARCH(1), di mana pada model EGARCH hampir sama seperti model TGARCH(1) bedanya disini hanya pemakaian bentuk ln pada Persamaan (29) menunjukkan bahwa bersifat Eksponensial.

Uji Signifikansi Parameter

Untuk mengetahui model terbaik, maka perlu dilakukan pengujian signifikansi parameter pada Tabel 11 menunjukkan hasil estimasi parameter model dugaan sementara dan nilai *probability* untuk pengujian signifikansi parameter. Pengujian signifikansi parameter untuk model ARIMA(1,1,1)-GARCH(1,2)-EGARCH(1) adalah sebagai berikut:

Pada Tabel 9 nilai *probability* parameter model ARIMA(1,1,1)-GARCH(1,2)-EGARCH(1) < $\alpha = 0,100$, maka diputuskan menolak H_0 , dan disimpulkan bahwa parameter model model ARIMA(1,1,1)-GARCH(1,2)-EGARCH(1) signifikan. Berdasarkan pengujian signifikan parameter diperoleh kesimpulan bahwa model yang memiliki parameter yang signifikan untuk data Z_t^* setelah dilakukan *differencing* orde 1 adalah model ARIMA(1,1,1)-GARCH(1,2)-EGARCH(1).

Pemilihan Model Terbaik

Dari tabel 11, dapat ditulis persamaan model ARIMA(1,1,1)-GARCH(1,2)-EGARCH(1) dengan Persamaan (31) sebagai berikut:

$$Z_t = 214,148 + 0,139Z_{t-1} + 0,861Z_{t-2} + a_t - 0,968a_{t-1}$$

$$\ln \sigma_t^2 = 8,693 - 0,485 \left| \frac{e_{t-1}}{\sigma_{t-1}} \right| - 0,474 \frac{e_{t-1}}{\sigma_{t-1}} + 1,281 \ln \sigma_{t-1}^2 - 0,871 \ln \sigma_{t-2}^2$$

ARCH-LM

Nilai heteroskedastisitas menggunakan Uji ARCH-LM dan pada 15.

Tabel 12. Uji ARCH-Lagrange Multiplier

<i>F-statistic</i>	0,352
<i>Probability</i>	0,549

Pada Tabel 15 nilai *probability* = 0,728 > $\alpha = 0,100$, disimpulkan H_0 gagal ditolak, maka dapat disimpulkan bahwa tidak terdapat efek ARCH pada data residual. Setelah tidak ada efek ARCH maka model ini bisa digunakan untuk peramalan.

Hasil Peramalan

Berdasarkan model terbaik yang diperoleh, yaitu model ARIMA(1,1,1)-GARCH(1,2)-EGARCH(1), maka dapat dilakukan peramalan. Hasil peramalan untuk nulan Juli 2017 sampai dengan Desember 2017 dapat dilihat pada Tabel 13. Notasi Z_t^* adalah

hasil peramalan berdasarkan data transformasi $Z_t^{1,210}$. Untuk data peramalannya harus dikembalikan ke data Z_t dengan transformasi $Z_t^{*1/1,210}$. Dapat dilihat bahwa hasil peramalan mengalami *trend* naik untuk periode Juli 2017 sampai dengan Desember 2017.

Tabel 16. Peramalan model EGARCH

t	Z_t
79	5.797,36
80	5.826,03
81	5.854,67
82	5.883,28
83	5.911,87
84	5.940,42

Kesimpulan

Berdasarkan analisis yang telah dilakukan, maka dapat diperoleh kesimpulan bahwa model terbaik pada studi kasus IHSG bulan Januari 2011 sampai dengan Juni 2017 adalah model ARIMA(1,1,1)-GARCH(1,2)-EGARCH(1) dan hasil peramalan IHSG dengan menggunakan model ARIMA(1,1,1)-GARCH(1,2) EGARCH(1) diperoleh bahwa terdapat *trend* naik pada periode Juli 2017 sampai dengan Desember 2017.

Daftar Pustaka

Ariefianto, M. D. (2012). *Ekonometrika Esensi dan Aplikasi dengan Menggunakan Eviews*. Jakarta: Erlangga.
 Aswi & Sukarna. (2006). *Analisis Deret Waktu: Teori dan Aplikasi*. Makassar: Andira Publisher.
 Bollerslev. (1985). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*. Vol. 3, No. 1.

Dzikevicius, A. & Saranda S. (2010). EMA Versus SMA Usage To Forecast Stock Market: The Case of S&P 500 And OMX Baltic Benchmark. *Business. Theory And Practice*. Vol. 3, No. 3.
 Glosten, Lawrence R., Jagannathan R. & David E. R. (1993), "On The Relation Between The Expected Value And The Volatility of The Nominal Excess Return On Stock," *Journal of Finance*. Vol. 8, No. 4.
 Gujarati, D. N. (2003). *Basic Econometrics*. New York: McGraw-Hill.
 Hanke, J. E., Reitsch, A. G. & Wichern, D. W. (2005). *Business Forecasting Eight Edition*. Singapore: Prentice-hall.
 Kabasarang, D. C, Adi, S, Bambang, S. Uji Normalitas Menggunakan Statistik Jaqure-Bera Berdasarkan Metode Bootstrap, *Journal Matematika*. Vol. 8, No. 1.
 Makridakis, Wheelwright & Mcgee. (1995). *Metode dan Aplikasi Peramalan*. Jakarta: Erlangga.
 Nelson, D. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach, *Journal of Econometrics*. Vol. 9, No. 5.
 Prihandini, Yoseva Agung. (2015). Penerapan Model EGARCH pada Estimasi Volatilitas Harga Minyak Kelapa Sawit. Bukit Jimbaran, *Journal Matematika*. Vol 4, No. 3.
 Wei, W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods*. New York: Pearson.
 Widarjono, A. (2013). *EKONOMETRIKA: Pengantar dan Aplikasinya*. Yogyakarta: UPP STIM YKPN.
 Wilson, J. H & Keating B. (2007). *Business Forecasting with Accompanying Excel-Based Forecast Software*. New York: McGraw-Hill.
 Zhang, G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Journal Neurocomputing*. Vol. 5, No. 1.