

# IDENTIFIKASI MODEL I-GARCH (INTEGRATED GENERALIZED AUTOREGRESSIVE CONDITIONALLY HETEROCEDASTIC) UNTUK PERAMALAN VALUE AT RISK

Nendra Mursetya Somasih Dwipa

Universitas PGRI Yogyakarta

email: [ndwipa@gmail.com](mailto:ndwipa@gmail.com)

## Abstrak

*A stock returns data are one of type time series data who has a high volatility and different variance in every point of time. Such data are volatile, setting up a pattern of asymmetrical, having a nonstationary model, and that does not have a constant residual variance (heteroscedasticity). A time series ARCH and GARCH model can explain the heteroscedasticity of data, but they are not always able to fully capture the asymmetric property of high frequency. Integrated Generalized Autoregressive Heteroskedasticity (IGARCH) model overcome GARCH weaknesses in capturing unit root. Furthermore IGARCH models were used to estimate the value of VaR as the maximum loss that will be obtained during a certain period at a certain confidence level. The aim of this study was to determine the best forecasting model of Jakarta Composite Index (JSI). The model had used in this study are ARCH, GARCH, and IGARCH. From the case studies were carried out, the result of forecasting volatility of stock index by using IGARCH(1,1) obtained log likelihood values that 3857,979 to the information criteria AIC = -6,3180; BIC = -6,3013; SIC = -6,3180; dan HQIC = -6,3117. Value of VaR movement of the JCI if it becomes greater the investment is Rp.500,000,000.00 with a confidence level of 95% on the date of July 2, 2015 using a model IGARCH (1,1) is Rp7.166.315,00.*

**Keywords:** Forecasting, volatility, IGARCH, VaR

## 1. PENDAHULUAN

Investasi berkaitan dengan penempatan dana ke dalam bentuk aset yang lain selama periode tertentu dengan harapan tertentu. Aset yang menjadi objek investasi seseorang secara umum terbagi menjadi dua hal, yaitu aset riil dan aset keuangan. Aset riil berkaitan dengan infrastruktur yang dapat memberikan dampak langsung terhadap kapasitas produktif objek investasi. Sedangkan aset keuangan memiliki kontribusi secara tidak langsung terhadap kapasitas produktif suatu perekonomian, karena aset ini memisahkan kepemilikan dan manajemen dalam suatu perusahaan dan

memfasilitasi pemindahan dana untuk perusahaan dengan peluang investasi yang menarik (Zvie Bodie:2006). Kegiatan investasi yang akan dilakukan di negara Indonesia dipengaruhi berbagai faktor. Bervariasinya faktor tersebut menjadikan seorang investor perlu memiliki kecermatan dalam mengambil keputusan. Salah satu aspek yang dapat menggambarkan kondisi perekonomian di Indonesia adalah besarnya nilai Indeks Harga Saham Gabungan (IHSG). Indeks ini meliputi seluruh saham yang diperdagangkan di Bursa Efek Indonesia (BEI).

Penyelidikan tentang return saham (Mehmet:2008) mengatakan

bahwa return keuangan memiliki tiga karakteristik. Pertama pengelompokan volatilitas, artinya perubahan sangat besar dapat terjadi pada periode waktu tertentu dan perubahan kecil di periode yang lain. Kedua adalah fat tailedness (excess kurtosis), artinya return keuangan sering menampilkan ekor lebih besar dari distribusi normal standar. Ketiga adalah efek leverage, adalah suatu keadaan dimana kondisinya *bad news* dan *good news* memberi pengaruh yang tidak simetris dalam volatilitasnya.

Model *generalized autoregressive conditional heteroskedasticity* (GARCH) menangkap tiga karakteristik utama pada *return* keuangan. Perkembangan tipe model GARCH dimulai (Engle: 1982) yang memperkenalkan ARCH untuk model heteroskedastisitas dengan melihat hubungan variansi bersyarat dari kombinasi linear kuadrat di masa lalu. Selanjutnya Bollersev (1986) memperkenalkan model *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) sebagai pengembangan model ARCH. Model GARCH merupakan model yang lebih sederhana dengan banyaknya parameter yang lebih sedikit dibandingkan model ARCH berderajat tinggi.

ARCH dan GARCH merupakan model runtun waktu yang dapat menjelaskan heteroskedastisitas pada data. Akan tetapi, model ARCH-GARCH tidak selalu dapat menangkap secara penuh adanya *unit root* dengan frekuensi tinggi, sehingga sangat sulit untuk memberikan keputusan kapan suatu pelaku saham akan memposisikan dirinya sebagai pembeli atau penjual. Selain itu model ARCH dan GARCH tidak mempertimbangkan *leverage effect* secara mendalam. Definisi *leverage effect* yaitu suatu keadaan *bad news* dan *good news* yang memberikan pengaruh asimetris terhadap volatilitas. Data dikatakan *bad news* ketika volatilitas mengalami penurunan sedangkan keadaan dikatakan *good news* ketika volatilitas mengalami kenaikan secara berkala. Francq dan Jakoian (1993) menemukan model *Integrated Generalized Autoregressive Conditional Heteroskedasticity* (IGARCH) yang dapat menutupi kelemahan model GARCH.

Pada tahun 1996 dikembangkan metode *Value at Risk* (VaR) dalam pengukuran resiko (JP Morgan:1996). Pada masa selanjutnya penggunaan metode ini sangat luas untuk mengukur berbagai jenis resiko karena selain untuk mengukur resiko atas aset tunggal juga bisa digunakan untuk mengukur resiko

atas aset dalam suatu portofolio. Metode *Value at Risk (VaR)* merupakan suatu metode pengukuran risiko yang secara statistik mengestimasi kerugian maksimum yang mungkin terjadi atas suatu portofolio pada tingkat kepercayaan (*confidence level*) tertentu (Best,1998).

## 2. KAJIAN TEORI

### 2.1 Stasioneritas

**Definisi 2.1.1** (Rosadi, 2006) Misalkan  $\mathcal{T}$  menyatakan himpunan dari semua vector  $\{t = (t_1, t_2, \dots, t_n)' \in T^n: t_1 < t_2 < \dots < t_n, n = 1, 2, \dots\}$ , fungsi distribusi bersama (joint distribution/cumulative distribution function) dari  $\{X_t, t \in T\}$  adalah fungsi  $\{F_t(\cdot), t \in \mathcal{T}\}$  didefinisikan pada  $t = (t_1, t_2, \dots, t_n)'$ ,  $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$  sebagai

$$\begin{aligned} F_{X_t}(x, t) = F_t(x) &= F_{X_{t_1}, X_{t_2}, \dots, X_{t_n}}(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) \\ &= P(X_{t_1} \leq x_1, X_{t_2} \leq x_2, \dots, X_{t_n} \leq x_n) \\ F_t(x) &= \sum_{i=1}^T P_x(x_i) \\ &= P_x(x_1) + P_x(x_2) + \dots + P_x(x_t) \end{aligned}$$

untuk data diskrit, dan untuk data kontinu

$$\begin{aligned} F_x(x, t) = F_t(x) &= F_{X_{t_1}, X_{t_2}, \dots, X_{t_n}}(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) \\ &= P(X_{t_1} \leq x_1, X_{t_2} \leq x_2, \dots, X_{t_n} \leq x_n) \\ &= \prod_{i=1}^T f_x(x_i) \\ &= \int f_x(x_1) dx + \int f_x(x_2) dx + \dots + \int f_x(x_t) dx \end{aligned}$$

**Definisi 2.1.2** (Tsay, 2005) Suatu proses runtun waktu disebut stasioner dengan kuat (*strictly stationary*) jika fungsi distribusi bersama (CDF) dari  $X_1, X_2, \dots, X_k$  sama dengan fungsi distribusi bersama dari  $X_{t+1}, X_{t+2}, \dots, X_{t+k}$  yaitu

$$F_{X_1, X_2, \dots, X_k}(x_1, x_2, \dots, x_k) = F_{X_{t+1}, X_{t+2}, \dots, X_{t+k}}(x_{t+1}, x_{t+2}, \dots, x_{t+k})$$

Dengan kata lain seluruh sifat-sifat statistik dari proses yang bersifat *strictly stationary* tidak berubah karena pergeseran waktu.

**Definisi 2.1.3** (Tsay, 2005) Proses runtun waktu  $\{X_t, t \in T\}$  dengan  $T = \mathbb{Z} = \{0, \pm 1, \pm 2, \dots\}$  disebut proses *Wide – Sense Stationary* jika memenuhi

- i.  $E(|X_t|^2) < \infty, \forall t \in \mathbb{Z}$
- ii.  $E(X_t) = \mu$ , suatu konstanta yang independen dengan  $t, \forall t \in \mathbb{Z}$
- iii.  $Cov(X_t, X_{t+k}) = Cov(X_{t+1}, X_{t+1+k}) = \dots = Cov(X_{t+p}, X_{t+p+k})$

Proses “*Wide – Sense Stationary*” sering juga disebut “*weakly stationary*”, “*covariance stationary*”, atau “*second order stationary*”.

**Teorema 2.1.4** (Tsay, 2005) Jika  $\{X_t\}$  stasioner, maka  $Cov(X_t, X_{t+k}) = Cov(X_{t-k}, 0)$  yakni fungsi kovariansi hanya bergantung pada kepada jarak

waktu  $(t - k)$  dan tidak bergantung pada  $t$  dan/ atau  $k$  secara sendiri-sendiri.

## 2.2 Model Runtun Waktu Stasioner

### 2.2.1 Proses Autoregressive (AR)

$X_t$  disebut sebagai proses autoregressive orde 1 atau AR(1) apabila

$$X_t = aX_{t-1} + \varepsilon_t,$$

dengan  $\varepsilon_t$  merupakan proses white noise  $(\mu, \sigma_t^2)$  dan  $a \in \mathbb{R}$ .

Misalkan

$$\tilde{X}_t = X_t - E(X_t)$$

$\tilde{\varepsilon}_t = \varepsilon_t - E(\varepsilon_t)$ , dengan  $E(\tilde{\varepsilon}_t) = 0$

dengan menganggap sistem mulai dari  $t = 0$ ,  $\mathbf{X}_0$  suatu konstanta atau non stokastik melalui substitusi berulang diperoleh

$$\tilde{X}_t = a^t \tilde{X}_0 + \sum_{j=0}^{t-1} a^j \tilde{\varepsilon}_{t-j}$$

Didapatkan  $E(\tilde{X}_t) = a^t \tilde{X}_0$ ,  $E(\tilde{X}_0) = \tilde{X}_0$  diasumsikan sebagai suatu konstanta

$$\text{Var}(\tilde{X}_t) = \sum_{j=0}^{t-1} a^{2j} \sigma^2$$

Cov  $(\tilde{X}_{t+k}, \tilde{X}_t) =$

$$E\left(\sum_{j=0}^{t+k-1} a^j \tilde{\varepsilon}_{t+k-j} \sum_{i=0}^{t-1} a^i \tilde{\varepsilon}_{t-i}\right)$$

$$= \sum_{i=0}^{t-1} a^{k+2i} \sigma^2$$

Proses autoregressive orde  $p$  atau AR( $p$ ) dapat dinyatakan sebagai

$$X_t = a_1 X_{t-1} + a_2 X_{t-2} + \dots + a_p X_{t-p} +$$

$\varepsilon_t$

$$= \sum_{i=1}^p a_i X_{t-i} + \varepsilon_t$$

dengan  $t \in \mathbb{Z}$ ,  $a_1, a_2, \dots, a_p \in \mathbb{R}$ , merupakan proses white noise  $(0, \sigma^2)$ .

### 2.2.2 Proses Moving Average (MA)

Model yang lain adalah proses moving average orde 1 atau MA(1) yang didefinisikan sebagai

$$X_t = \varepsilon_t + \theta \varepsilon_{t-1},$$

dengan  $t \in \mathbb{Z}$ ,  $\varepsilon_t$  suatu proses white noise  $(0, \sigma^2)$ ,  $\theta \in \mathbb{R}$  didapatkan

$$E(X_t) = 0,$$

$$E(X_t^2) = \sigma^2(1 + \theta^2) < \infty, \text{ dan}$$

$$\gamma_X(t+h, t) = \begin{cases} (1 + \theta^2)\sigma^2 & , h = 0 \\ \theta\sigma^2 & , h = \pm 1 \\ 0 & , |h| > 1 \end{cases}$$

Proses moving average orde  $q$  atau MA( $q$ ) dapat dinyatakan sebagai

$$\begin{aligned} X_t &= \varepsilon_t + b_1 \varepsilon_{t-1} + b_2 \varepsilon_{t-2} + \dots \\ &\quad + b_q \varepsilon_{t-q} \\ &= \varepsilon_t + \sum_{j=1}^q b_j \varepsilon_{t-j} \end{aligned}$$

dengan  $b_j \in \mathbb{R}$  untuk  $j = 1, 2, 3, \dots, q$  dan  $\varepsilon_t$  bersifat white noise.

### 2.2.3 Proses Autoregressive Moving Average (ARMA)

Suatu proses  $X_t$  disebut proses autoregressive moving average orde ke- $p$  dan ke- $q$  atau ARMA( $p, q$ ) apabila berbentuk

$$X_t - a_1 X_{t-1} - \dots - a_p X_{t-p} = \varepsilon_t +$$

$$b_1 \varepsilon_{t-1} + b_2 \varepsilon_{t-2} + \dots + b_q \varepsilon_{t-q}$$

$$X_t =$$

$$\sum_{i=1}^p a_i X_{t-i} + \sum_{j=1}^q b_j \varepsilon_{t-j} + \varepsilon_t$$

dengan  $a_1, a_2, \dots, a_p, b_1, b_2, \dots, b_q \in \mathbb{R}$ ,  $\varepsilon_t$  merupakan proses *white noise*  $(0, \sigma^2)$ .

Dengan menggunakan operator *lag* maka proses ARMA (p, q) dapat dinyatakan menjadi

$D(B) X_t = C(B) \varepsilon_t$  dimana

$$D(z) = (1 - a_1z - a_2z^2 - \dots - a_pz^p)$$

$$C(z) = (1 + b_1z + b_2z^2 + \dots + b_qz^q)$$

Model ARMA (p,q) dapat mengatasi masalah tingginya derajat AR(p) dan MA(q) karena memberikan model yang lebih sederhana.

### 2.3 Model Autoregressive Conditional Heterocedastic (ARCH)

Ketiga model umum runtun waktu AR(p), MA(q), dan ARMA(p,q) mengasumsikan bahwa ragam bersifat homokedastik. Pada kenyataannya untuk mayoritas data di bidang keuangan ragam bersifat heterokedastik.

Pada model ARCH(a), diperoleh variansi dari  $r_t$  kondisional terhadap informasi masa lalu sebagai

$$Var(r_t | \mathcal{F}_{t-1}) = E(\varepsilon_t^2 | \mathcal{F}_{t-1}) = \sigma_t^2$$

Dapat digambarkan dengan persamaan

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_m \varepsilon_{t-m}^2 =$$

$$\alpha_0 + \sum_{i=1}^a \alpha_i \varepsilon_{t-i}^2$$

dimana  $\alpha_0 > 0, \alpha_i \geq 0, i = 1, 2, \dots, a$ .

Kondisi  $\alpha_i \geq 0$  diperlukan agar persamaan volatilitas tidak negatif. Apabila  $\alpha_i = 0, \forall i$ , maka variansi bersyarat  $\sigma_t^2$  akan menjadi konstanta  $\alpha_0$ .

Untuk model ARCH (1) dapat dituliskan sebagai:

$$\varepsilon_t = \sigma_t v_t, \sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2, \alpha_0 >$$

$$0, \alpha_1 \geq 0, v_t \sim NIID(0,1)$$

Hasil ini menyatakan bahwa bentuk *tail distribution* dari  $\varepsilon_t$ , yakni  $P(\varepsilon_t > x)$  selalu lebih tebal dari distribusi normal. Dengan kata lain, fungsi *shock*  $\varepsilon_t$  dari model bersyarat Gaussian ARCH(1) akan membangkitkan lebih banyak kejadian ekstrem dibandingkan dengan proses *white noise* biasa yang berdistribusi Gaussian.

### 2.4 Model Generalized Autoregressive Conditional Heterocedastic (GARCH)

Model GARCH dikembangkan [2] dalam rangka untuk mengefisienkan ordo besar yang mungkin terjadi pada model ARCH.

Definisikan  $\varepsilon_t = r_t - \mu_t$  yaitu *mean corrected log return*,  $\varepsilon_t$  dikatakan mengikuti model GARCH (a, b) apabila

$$\varepsilon_t = \sigma_t v_t \text{ dan}$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^b \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^a \beta_j \sigma_{t-j}^2$$

dengan  $v_t$  berdistribusi IID (independent identically distributed)

$N(0,1), \alpha_0 > 0, \alpha_i \geq 0, i = 1, 2, \dots, a$

,  $\beta_j \geq 0, j = 1, 2, \dots, b, \sum_{i=1}^{\max(m,s)} (\alpha_i +$

$\beta_j) < 1$ . Diasumsikan  $E(\varepsilon_t | \mathcal{F}_{t-1}) = 0$

dan  $Var(\varepsilon_t | \mathcal{F}_{t-1}) = E(\varepsilon_t^2 | \mathcal{F}_{t-1}) = \sigma_t^2$ .

Dari model di atas, tersirat suatu keterbatasan dari model GARCH ini bagaimana kondisi non-negatif mungkin saja dilanggar oleh metode estimasi ini karena koefisien dari model berpeluang negatif. Hal lain yang menjadi sifat model GARCH adalah [7]

1. Model GARCH dalam peramalan volatilitas rendah akurasinya
2. Pada banyak data saham, *return* saham memiliki pengaruh asimetrik yang tidak terdeteksi oleh model GARCH

### 3. METODE PENELITIAN

Penelitian ini mengambil data Indeks Harga Saham Gabungan (IHSG) yang diperoleh dari laman <http://www.yahoo.finance.com>. Urutan pelaksanaan penelitian dilakukan dengan tahapan berikut ini.

1. Mengambil data runtun waktu IHSG
2. Menghitung return IHSG
3. Uji normalitas data runtun waktu
4. Uji stasioneritas data runtun waktu
5. Identifikasi model ARIMA
6. Uji efek ARCH/GARCH
7. Estimasi model ARCH/GARCH
8. Uji Diagnostik Pasca Analisis Model ARCH/GARCH
9. Uji akar unit
10. Pemodelan IGARCH
11. Peramalan
12. Perhitungan Value at Risk (VaR)

### 3.1. Model Integrated GARCH

Model IGARCH digunakan apabila terdapat *unit root* pada model GARCH yaitu dipenuhinya kondisi

$$\sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j = 1$$

Menurut Francq dan Zakoian (2010) bentuk umum model IGARCH(p,q) sebagai berikut:

$$\sigma_t^2 = \sum_{i=1}^p \alpha_i a_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

Pada saat varians bersyarat tidak didapatkan, dimana peramalan volatilitas tidak memenuhi kondisi *mean reverting* yaitu konvergensi peramalan tidak dipenuhi, maka model IGARCH relevan untuk digunakan.

Karena fenomena  $\alpha + \beta = 1$ , maka  $\beta$  dapat diganti dengan parameter  $\lambda$  yang nilainya berada pada interval  $[0,1]$ . Parameter  $\lambda$  memberi arti sebagai skala bobot dari suatu data terhadap data sebelumnya yang disebut faktor peluruh. Besarnya  $\lambda$  cukup akurat memodelkan volatilitas meskipun nilainya berbanding terbalik dengan besar pengaruhnya terhadap volatilitas. Jelas bahwa  $\lambda$  merupakan suatu ukuran akurasi terhadap pemodelan volatilitas dimana volatilitas yang tinggi pada periode saat ini menunjukkan tetap tingginya volatilitas tersebut pada periode selanjutnya.

Pembahasan selanjutnya menerangkan bahwa karena  $\beta$  telah diganti dengan suatu parameter  $\lambda$ , cukup jelas bahwa  $\alpha = 1 - \lambda$ . Parameter ini memberi arti sebagai ukuran intensitas reaksi terhadap suatu volatilitas yang dipengaruhi oleh kondisi ekonomi. Semakin besar nilai  $\lambda$  menunjukkan bahwa semakin kecil reaksi volatilitas terhadap informasi pasar periode sebelumnya.

### 3.2. Value at Risk (VaR)

Salah satu instrumen untuk mengukur resiko adalah VaR (*Value at Risk*). VaR dapat didefinisikan sebagai estimasi potensi kerugian maksimal pada periode tertentu dengan tingkat keyakinan tertentu dalam kondisi keadaan (pasar) yang normal. Nilai VaR selalu disertai dengan probabilitas yang menunjukkan seberapa mungkin kerugian yang terjadi akan kurang dari nilai VaR tersebut. Kelebihan dari VaR adalah bahwa metode ini fokus pada *downside risk*, tidak tergantung pada asumsi distribusi dari return, dan pengukuran VaR dapat diterapkan pada seluruh produk-produk perdagangan finansial maupun derivatifnya.

Aplikasi dari pendekatan ARCH/GARCH dan IGARCH diantaranya untuk keadaan penyebaran data dimana volatilitas return menjadi isu utama. Banyak bank dan institusi

finansial lainnya menggunakan konsep VaR sebagai jalan untuk mengukur resiko yang dihadapi oleh portofolionya. Nilai VaR 1% artinya besarnya uang yang memiliki 99% kepastian untuk melebihi setiap kerugian di hari berikutnya. Para statistikawan menyebutnya sebagai 1 persen kuantil, karena mengartikan 1% dari hasil yang buruk dan 99% hasil lebih baik. VaR dengan tingkat kepercayaan  $(1-\alpha)$  memiliki rumus berikut ini.

$$VaR_{(1-\alpha)} = -W_0R^*$$

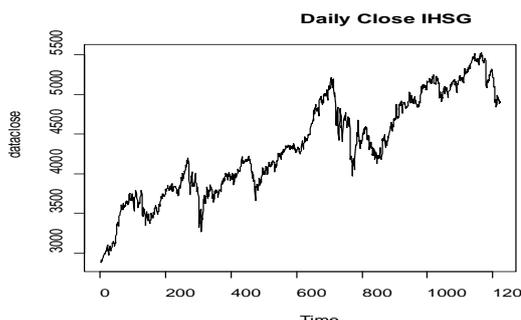
Dengan  $R^* = \mu - Z_\alpha\sigma_t$  adalah kuantil dari distribusi *return* pada waktu ke-t.

## 4. HASIL DAN PEMBAHASAN

Penelitian ini mengambil contoh kasus pada pergerakan indeks harga saham gabungan (IHSG) dengan data yang digunakan adalah data harian pada periode 30 Juni 2010 sampai dengan 1 Juli 2015 [9]

### 4.1. Uji Normalitas dari Data Runtun Waktu Univariat

Data IHSG yang dianalisis terdiri dari 1222 data berbentuk runtun waktu. Plot dari data harga penutupan IHSG terlihat dalam grafik berikut ini.

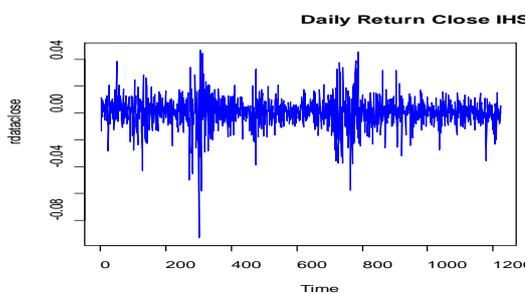


Gambar 4.1 Data Penutupan IHSG Periode 30 Juni 2010 sampai 1 Juli 2015

Secara visual terlihat bahwa data nilai penutupan IHSG mengandung tren. Pada penelitian ini data yang dianalisis bukan data mentah melainkan data pengembaliannya(*return*), dalam hal ini merupakan nilai *continuously compound return*, yaitu

$$r_t = \ln(1 + R_t) = \ln \frac{P_t}{P_{t-1}} = \ln P_t - \ln P_{t-1}.$$

Dimana  $P_t$  adalah nilai indeks saham pada waktu ke- $t$ , dan  $P_{t-1}$  adalah nilai indeks saham pada waktu ke  $t-1$ . Berikut plot grafik data pengembalian IHSG.



Gambar 4.2 Data Pengembalian IHSG Periode 30 Juni 2010 sampai 1 Juli 2015

Dari plot di atas tampak adanya clustering pada data return tersebut. Dengan menggunakan program R didapatkan nilai kurtosis 6,572254. Dari nilai excess kurtosis yang positif menunjukkan data tidak normal, akan lebih jelas lagi apabila dilihat secara visual dari histogram data.

Didapatkannya fenomena bahwa data yang diambil tidak berdistribusi normal mendatangkan kebutuhan untuk memenuhi asumsi normalitas tersebut. Salah satu hal yang dapat mengatasi permasalahan tersebut adalah dengan melakukan transformasi data. Transformasi yang diambil dalam penelitian ini adalah dengan melakukan pembedaan, kemudian mengambil nilai mutlak dari data, dan dilanjutkan dengan transformasi Box-Cox. Dengan bantuan program R Diperoleh nilai orde estimasi  $\lambda$  optimal adalah 0,3079685. Hasil transformasi telah berbentuk distribusi normal, ditunjukkan dengan hasil  $p$ -value = 0.4179 > 5%.

#### 4.2. Uji Stasioneritas Data Runtun Waktu

Asumsi stasioneritas dalam analisis data runtun waktu merupakan suatu hal yang sangat penting. Uji Augmented Dickey Fuller merupakan salah satu yang paling sering digunakan dalam pengujian stasioneritas data. Dari *output* program R uji ADF diperoleh

bahwa  $p\text{-value} = 0.01 < 5\%$  artinya hipotesis nol ditolak menunjukkan tidak adanya akar unit dalam data artinya data stasioner.

**4.2.1 Estimasi Parameter dari Model**

Selanjutnya diidentifikasi model *Autoregressive Moving Average* (ARMA) yang tepat untuk menggambarkan data hasil pembedaan. Berdasarkan dari plot tersebut terlihat bahwa fungsi ACF/PACF signifikan pada lag ke-1 dan meluruh menuju nol untuk lag berikutnya. Selanjutnya dilakukan estimasi terhadap beberapa alternatif model berikut ini. Dapat dimengerti bahwa model yang mungkin untuk menggambarkan data menurut prinsip kesederhanaan pemodelan, dipilih dari beberapa alternatif model yaitu (ARIMA(1,1,0), ARIMA(2,1,0), ARIMA(1,1,1), ARIMA(0,1,1), ARIMA(0,1,2), ARIMA(2,1,1), ARIMA(1,1,2), dan ARIMA (5,1,0). Dari plot ACF terlihat bahwa residual sudah merupakan proses *white noise*, ditandai dengan tidak adanya lag ( $\geq 1$ ) yang keluar garis batas interval.

**4.3. Rangkuman Hasil dan Pemilihan Model Terbaik**

Signifikansi nilai estimasi dari koefisien, galat baku (*standar error*) koefisien, dan nilai-nilai statistik untuk pengecekan diagnostik bagi model-

model yang diamati disajikan dalam tabel berikut.

Tabel 4.1 Signifikansi Koefisien ARIMA

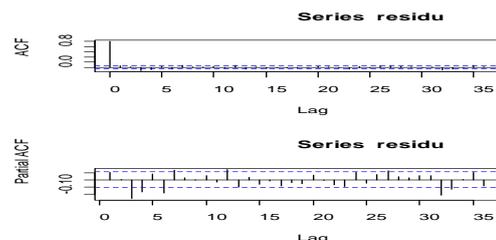
	ARIMA (1,1,0)	ARIMA (2,1,0)	ARIMA (0,1,1)	ARIMA (0,1,2)	ARIMA (1,1,1)	ARIMA (2,1,1)	ARIMA (1,1,2)	ARIMA (2,1,2)	ARIMA (5,1,0)
a <sub>1</sub>	√	√			√	√	X	X	√
a <sub>2</sub>		√				X		X	√
a <sub>3</sub>									√
a <sub>4</sub>									√
a <sub>5</sub>									√
b <sub>1</sub>			√	√	√	√	√	X	
b <sub>2</sub>				√				√	√
RMS E	7.85e-02	7.36e-02	6.81e-02	6.73e-02	6.72e-02	6.72e-02	6.711e-02	6.70e-02	7.00e-02
AIC	-2739.29	2905.77	3081.79	-3115.6	-	-	-3115.63	-3114.4	-
SBC	-2729.08	2890.46	3071.58	3100.28	3097.54	3091.92	-3095.21	3088.87	3009.73
BIC									

Ket:

- √: Koefisien hasil estimasi signifikan
- X: Koefisien hasil estimasi tidak signifikan

Didapat bahwa model ARIMA (0,1,2) menjadi model terbaik dengan nilai statistik uji-t lebih dari nilai statistik tabel t (df=1221-1=1220;  $\alpha=2,5\%$ ) untuk seluruh koefisien serta berdasarkan nilai RMSE, AIC, dan BIC yang paling minimum yang didukung dengan prinsip kesederhanaan pemodelan.

**4.4. Pengujian Efek ARCH/GARCH**



Gambar 4.3 Plot Fungsi ACF/PACF dari Data Residual

Terlihat pada data bahwa tidak ada indikasi yang kuat adanya korelasi serial dari data (kecuali pada beberapa lag besar di atas batas  $\frac{Z_{\alpha}}{\sqrt{n-1}} = \frac{1,96}{\sqrt{1220}} = 0,056$ ). Berdasarkan statistik QLjung-Box hipotesis nol mengenai tidak adanya korelasi sampai pada lag ke -5 diterima pada tingkat uji 5%.

Terlihat bahwa meski data residual tidak berkorelasi, namun variansi dari residual menunjukkan adanya korelasi. Hal yang sama juga ditunjukkan dari hasil uji QLjung-Box pada tingkat uji 5%.

#### 4.5. Estimasi Model ARCH/GARCH

Berpijak pada plot autokorelasi dari residual kuadrat yang mengandung komponen ARCH/GARCH, berikut ini akan dicoba menggunakan beberapa model untuk residual tersebut.

Hasil estimasi model ARCH/GARCH yang lain ditampilkan dalam tabel berikut ini.

Tabel 4.2: Ringkasan Pemodelan ARCH/GARCH

	Mu	ma1	ma2	Omega	alpha1	alpha2	alpha3	beta1	beta2
ARCH (1)	0.227012 Pr(> t ) =0.0000 ***	0.2618 Pr(> t ) =0.0000 ***	0.0407 Pr(> t ) 0.0937	0.0043 Pr(> t ) 0.00	0.0612 Pr(> t ) =0.017 **				
$\sigma_t^2 = 0.227012 + 0.261899 \epsilon_{t-1} + 0.004391 + 0.061231 \epsilon_{t-1}^2$									
ARCH(2)	Convergence problem								
ARCH (3)	0.22608 Pr(> t ) =0.000 ***	0.25802 Pr(> t ) =0.00000 ***	0.03975 Pr(> t ) =0.1339	0.0041 Pr(> t ) 0.00000 ***	0.06056 Pr(> t ) 0.0412 0.8717	0.00483 Pr(> t ) 0.7717	0.0592 Pr(> t ) )		
GARCH (1,1)	0.2240 Pr(> t ) =0.0000 ***	0.2492 Pr(> t ) =0.00000 ***	0.0323 Pr(> t ) =0.186	0.0001 Pr(> t ) 0.6383 0.001	0.0306 Pr(> t ) 0.001			0.9352 Pr(> t ) =0.000 ***	
$\sigma_t^2 = 0.224 + 0.24924 \epsilon_{t-1} + 0.00016 + 0.0306 \epsilon_{t-1}^2 + 0.9352 \sigma_{t-1}^2$									
GARCH (1,2)	0.2239 Pr(> t ) =0.000 ***	0.25 Pr(> t ) =0.000 ***	0.033 Pr(> t ) 0.177	0.0002 Pr(> t ) 0.0243 **	0.0527 Pr(> t ) 0.0002			0.0691 Pr(> t ) 0.344	0.817 Pr(> t ) 0.00 ***
$\sigma_t^2 = 0.224 + 0.25 \epsilon_{t-1} + 0.0002 + 0.0527 \epsilon_{t-1}^2 + 0.817 \sigma_{t-2}^2$									

#### 4.6. Uji Diagnostik Pasca Analisis Model ARCH/GARCH

##### 4.6.1 Uji ARCH LM

Dari tabel di atas didapatkan bahwa model yang lolos uji signifikansi adalah model ARCH(1), GARCH (1,1), dan GARCH(2,1) yang tereduksi menjadi GARCH(1,1). Selanjutnya dari model terpilih ini dilakukan uji diagnostik pasca analisis. Uji ini dilakukan untuk melihat apakah masih ada efek ARCH yang tersisa dalam residual hasil estimasi model. Pada model ARCH (1) didapatkan nilai LM dengan  $p$ -value < 0,05 untuk semua lag sehingga hipotesis nol ditolak, artinya pada model ARCH (1) masih terdapat efek ARCH, pada model GARCH (1,1) tidak terdapat efek ARCH, pada model GARCH(2,1) karena koefisien beta2 tidak signifikan, maka model GARCH (2,1) dalam hal ini tereduksi menjadi model GARCH(1,1) dan pada model sudah tidak terdapat efek ARCH.

##### 4.6.2 Uji Korelasi Serial untuk Residual yang Distandarisasi

Uji lain yang dapat dilakukan adalah uji korelasi serial dari residual kuadrat sampai lag ke - m dengan statistik QLjung-Box yang dibandingkan dengan kuantil dari distribusi  $\chi_m^2$  ataupun dari plot fungsi autokorelasi dan autokorelasi parsial dari residual kuadrat terstandarisasi.

Dari tabel didapat hasil

- a) model ARCH(1) tidak terdapat korelasi serial dalam residual kuadrat pada tingkat signifikansi 5%.
- b) model GARCH(1,1) disimpulkan bahwa hipotesis nol tidak ditolak artinya tidak terdapat korelasi serial dalam residual kuadrat pada tingkat signifikansi 5%.
- c) model GARCH(2,1) yang tereduksi menjadi GARCH (1,1) dapat disimpulkan bahwa hipotesis nol diterima artinya pada model ini tidak terdapat korelasi serial dalam residual kuadrat pada tingkat signifikansi 5%.

Dari hasil uji diagnostik pasca analisis yang telah dilakukan maka ditentukan model GARCH terbaik adalah model GARCH(1,1).

**4.7. Pemilihan Model Terbaik**

Meskipun dari analisis yang dilakukan telah menunjukkan beberapa model yang baik untuk digunakan menggambarkan data, untuk mendapatkan hasil yang komprehensif perlu membandingkan nilai log likelihood dan statistik kriteria informasi seperti AIC(Akaike), BIC (Bayes), SIC (Shibata), dan HQIC(Hannan-Quinn). Rangkuman statistik hasil analisis akan diberikan pada tabel berikut.

Tabel 4. 3 Rangkuman Hasil Pemodelan

Model	Pasca Analisis	Log Likelihood	AIC	BIC	SIC	HQIC
ARCH(1)	koefisien MA(2) tidak signifikan sehingga tereduksi menjadi model MA(1), melewati semua pasca analisis	1543.949	-2.5229	-2.5019	-2.5229	-2.5150
ARCH(2)	Model tidak konvergen					
ARCH(3)	Koefisien MA(2), $\alpha_1$ , $\alpha_2$ , dan $\alpha_3$ tidak signifikan	1546.211	-2.5233	-2.4940	-2.5234	-2.5123
GARCH(1,1)	koefisien MA(2) tidak signifikan sehingga tereduksi menjadi model MA(1), melewati semua pasca analisis	1551.711	-2.5340	-2.5088	-2.5340	-2.5245
GARCH(1,2)	Koefisien MA(2), $\omega$ , dan $\beta_1$ tidak signifikan	1552.802	-2.5341	-2.5048	-2.5342	-2.5231
GARCH(2,1)	Koefisien MA(2), $\omega$ , $\alpha_1$ , dan $\alpha_2$ tidak signifikan	1551.711	-2.5323	-2.5030	-2.5324	-2.5213
GARCH(2,2)	Koefisien MA(2), $\omega$ , $\alpha_1$ , $\alpha_2$ , dan $\beta_1$ tidak signifikan	1552.802	-2.5325	-2.4990	-2.5325	-2.5199

Memperhatikan hasil di atas, tercermin beberapa model relatif optimal dalam memodelkan data return IHSG. Dari hasil analisis terlihat bahwa model ARCH(1), dan GARCH(1,1) adalah model yang relatif paling baik dengan melihat nilai statistik kriteria informasi dan log likelihood. Model yang terpilih menjadi model terbaik dalam menggambarkan data adalah model GARCH(1,1) ditunjukkan dari kondisi semua koefisien signifikan dan nilai log likelihood yang paling besar dengan kriteria informasi paling minimum.

**4.8. Uji Adanya Akar Unit**

Dari model yang terpilih relatif baik selanjutnya dilakukan uji *unit root* (akar unit) dengan melihat hasil penjumlahan koefisien dari model yang didapat.

Tabel 4.4 Hasil Uji Unit Root

No	Model	Jumlah koefisien $\alpha$ dan $\beta$
1	ARCH(1)	0,0612
2	GARCH(1,1)	0,9659

Tampak bahwa hasil penjumlahan koefisien model GARCH(1,1) mendekati satu. Hal ini menunjukkan

terdapatnya akar unit dalam model sehingga model GARCH yang telah dilakukan perlu dilanjutkan ke model IGARCH

#### 4.9. Pemodelan IGARCH

Berdasarkan hasil uji *unit root* (akar unit) di atas dilakukan pemodelan IGARCH dengan hasil seperti berikut ini.

Tabel 4.5 Hasil Pemodelan IGARCH

Model	Log Likelihood	AIC	BIC	SIC	HQIC
IGARCH(1,1)	3857.979	-6.3180	-6.3013	-6.3180	-6.3117
IGARCH(1,2)	3858.247	-6.3168	-6.2959	-6.3168	-6.3089
IGARCH(2,1)	3858.645	-6.3175	-6.2965	-6.3175	-6.3096
IGARCH(2,2)	3861.571	-6.3206	-6.2955	-6.3207	-6.3112

Memperhatikan hasil pada tabel dia atas, terlihat bahwa model IGARCH(1,1) adalah model yang relatif terbaik dengannilai statistik kriteria informasi dan log likelihood paling minimum.

#### 4.10. Peramalan

Peramalan yang dilakukan adalah mencari nilai tersuai dari nilai perkiraan dan prediksi dari *mean* dan variansi dengan model terbaik yang telah diperoleh. Nilai Ramalan harga IHSG dengan model IGARCH(1,1) untuk 10 periode berikutnya ditunjukkan dalam tabel berikut.

Tabel 4.6 Peramalan Harga IHSG Model IGARCH(1,1)

Return IHSG	IHSG
-0,0001955	4901,853
-0,000001298	4901,838
-0,000001298	4901,824
-0,000001298	4901,809
-0,000001298	4901,794
-0,000001298	4901,78
-0,000001298	4901,765
-0,000001298	4901,75
-0,000001298	4901,736
-0,000001298	4901,721

#### 4.11. Perhitungan Value at Risk (VaR)

Dalam menghitung VaR, yang perlu dilakukan pertama kali adalah mengasumsikan dana yang dialokasikan untuk investasi. Dalam penelitian ini mengasumsikan dana yang digunakan untuk investasi sebesar Rp 500.000.000,00.

Dapat ditarik kesimpulan bahwa untuk periode 1 hari ke depan dari tanggal 1 Juli 2015 dapat diprediksi dengan model IGARCH(1,1), bahwa kerugian maksimum yang dapat ditoleransi investor dengan nilai investasi Rp 500.000.000,00 untuk tingkat kepercayaan 95% adalah Rp 7.166.315,00.

## 5. PENUTUP

### 5.1. Kesimpulan

Berdasarkan hasil pembahasan dalam penelitian, dapat diperoleh kesimpulan berikut ini.

1. Dari studi kasus yang dilakukan, diperoleh hasil peramalan volatilitas nilai IHSG dengan menggunakan model IGARCH(1,1) diperoleh nilai *log likelihood* yaitu 3857,979 dengan nilai kriteria informasi AIC = -6,3180; BIC = -6,3013; SIC = -6,3180; dan HQIC = -6,3117. Model tersebut terpilih menjadi model terbaik dalam menggambarkan data ditunjukkan dari nilai log likelihood yang paling besar dengan nilai kriteria informasi paling minimum.
2. Nilai VaR pergerakan nilai IHSG apabila diketahui besar nilai investasi adalah Rp 500.000.000,00 untuk tingkat kepercayaan 95% untuk satu periode ke depan menggunakan model IGARCH(1,1) adalah Rp 7.166.315,00.

### 5.2. Saran

Hasil analisis pergerakan nilai IHSG menggunakan model IGARCH merupakan model terbaik dari beberapa model yang digunakan pada studi kasus ini. Akan tetapi dalam usaha mengatasi keadaan asimetri pada data, diperlukan

model-model yang lain untuk memperbaiki kekurangan model GARCH. Model lain yang dapat digunakan untuk mengatasi masalah asimetri diantaranya adalah model EGARCH (*Exponential GARCH*), T-GARCH (*Threshold-GARCH*), APARCH (*Asymmetric Power ARCH*), dan GARCH Model with *Contemporaneous Conditional Asymmetry*.

## 6. REFERENSI

- Best, P. 1998. *Implementating Value at Risk*. West Sussex: John Wiley and Sons, Ltd.
- Bollerslev, T. 1986. Generalized Autoregressive Conditional Heterocedasticity. *J. Econometrics*. pp. 307-327.
- Francq, C and Zakoian, J.M. 2010. *GARCH Models (Structure, Statistical Inference and Financial Applications)*. Lille: A John Wiley and Sons, Ltd.
- Engle, R. The Use of ARCH/GARCH Models in Applied Econometrics. *Journal of Econometric Perspectives*. 1982; pp. 157-168.
- Mehmet, A. 2008. *Analysis of Turkish Financial Market with Markov Regime Switching Volatility Models*. Ankara: The Middle East Technical University.

Rosadi, D.2006. *Pengantar Analisis Runtun Waktu*. Yogyakarta: Andi.

Tsay, Ruey S. *Analysis of Financial Time Series*. Chicago: A John Wiley and Sons, Ltd.

Zvie Bodie, A. K. A. J. M. 2006. *Investments*. New York: McGraw-Hill.