

PERAMALAN *VALUE AT RISK* MENGGUNAKAN METODE *GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTIC*

Nendra Mursetya Somasih Dwipa

INTISARI

Data return saham merupakan salah satu jenis data runtun waktu yang memiliki volatilitas tinggi dan varians yang berbeda di setiap titik waktunya. Data tersebut berfluktuatif, membentuk pola asimetris, memiliki model yang nonstasioner, dan mempunyai variansi residual yang tidak konstan (heteroskedastisitas). ARCH dan GARCH merupakan model runtun waktu yang dapat menjelaskan keheteroskedastisitasan data. Selanjutnya model GARCH ini digunakan untuk mengestimasi nilai VaR sebagai kerugian maksimum yang akan didapat selama periode waktu tertentu pada tingkat kepercayaan tertentu. Tujuan dari penelitian ini adalah untuk mengetahui model peramalan terbaik dari nilai Indeks Harga Saham gabungan (IHSG). Model yang digunakan dalam penelitian ini adalah ARCH, dan GARCH. Hasil dari penelitian ini menunjukkan bahwa GARCH(1,1) adalah model terbaik nilai log likelihood 1551.711 dan nilai kriteria informasi AIC = -2.5340; BIC = -2.5088; SIC = -2.5340; dan HQIC = -2.5245. Model ini mendapatkan nilai Value at Risk (VaR) satu periode dengan taraf kepercayaan 95% Rp 3.622.420,50. untuk dana investasi Rp 500.000.000,00.

Kata Kunci: Peramalan, volatilitas, GARCH, VaR

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 [1].

Penyelidikan tentang *return* saham tahun 2008 [2] 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 keruncingan lebih besar dari distribusi normal standar. Ketiga adalah efek *leverage*, adalah suatu keadaan dimana kondisis bad news dan good news memberi pengaruh yang tidak simetris dalam volatilitasnya.

Model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) menangkap tiga karakteristik utama pada *return* keuangan. Perkembangan tipe model GARCH dimulai oleh tahun 1982 [3] yang memperkenalkan ARCH untuk model heteroskedastisitas dengan melihat hubungan variansi bersyarat dari kombinasi linear kuadrat di masa lalu. Selanjutnya pada 1986 [4] diperkenalkan 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 *heavy-tail property* 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. Pada tahun 1991 [5] ditemukan model *Exponential Generalized Autoregressive Conditional Heteroskedasticity* (EGARCH) yang dapat menutupi kelemahan model GARCH dalam menangkap ketidaksimetrisan *good news* dan *bad news* dengan memperhitungkan *leverage effect*.

Pada tahun 1996 [6] dikembangkan metode *Value at Risk (VaR)* dalam pengukuran resiko. Pada masa selanjutnya penggunaan metode ini sangat luas untuk mengukur berbagai jenis risiko karena selain untuk mengukur risiko atas aset tunggal juga bisa digunakan untuk mengukur risiko atas aset dalam suatu portofolio. Metode *Value at Risk (VaR)* [7] merupakan suatu metode pengukuran risiko yang secara statistik mengestimasi kerugian maksimum yang mungkin terjadi atas suatu portofolio pada tingkat kepercayaan (*confidence level*) tertentu.

STASIONERITAS

Definisi 1. 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 $\{X_t, t \in \mathcal{T}\}$ 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

$$F_X(x, t) = F_t(x) = F_{X_{t_1}, X_{t_2}, \dots, X_{t_n}}(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) = P(X_{t_1} \leq x_1, X_{t_2} \leq x_2, \dots, X_{t_n} \leq x_n)$$

$$F_t(x) = \sum_{i=1}^T P_x(x_i) = P_x(x_1) + P_x(x_2) + \dots + P_x(x_t)$$

untuk data diskrit, dan untuk data kontinu

$$F_x(x, t) = F_t(x) = F_{X_{t_1}, X_{t_2}, \dots, X_{t_n}}(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) =$$

$$P(X_{t_1} \leq x_1, X_{t_2} \leq x_2, \dots, X_{t_n} \leq x_n)$$

$$= \prod_{i=1}^T f_x(x_i) = \int f_x(x_1) dx + \int f_x(x_2) dx + \dots + \int f_x(x_t) dx$$

Definisi 2. 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 3. 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 1. 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.

PROSES AUTOREGRESSIVE (AR)

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

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

dengan ε_t merupakan proses *white noise* (μ, σ^2) dan $a \in \mathbb{R}$.

Misalkan

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

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

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

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

$$\begin{aligned} \text{Cov}(\tilde{X}_{t+k}, \tilde{X}_t) &= E(\sum_{j=0}^{t+k-1} a^j \tilde{\varepsilon}_{t+k-j} \sum_{i=0}^{t-1} a^i \tilde{\varepsilon}_{t-i}) \\ &= \sum_{i=0}^{t-1} a^{k+2i} \sigma^2 \end{aligned}$$

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

$$\begin{aligned} X_t &= a_1 X_{t-1} + a_2 X_{t-2} + \dots + a_p X_{t-p} + \varepsilon_t \\ &= \sum_{i=1}^p a_i X_{t-i} + \varepsilon_t \end{aligned}$$

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

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 $t \in \mathbb{Z}$, ε_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

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

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

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

$$\begin{aligned} X_t - a_1 X_{t-1} - \dots - a_p X_{t-p} &= \varepsilon_t + b_1 \varepsilon_{t-1} + b_2 \varepsilon_{t-2} + \dots + b_q \varepsilon_{t-q} \\ X_t &= \sum_{i=1}^p a_i X_{t-i} + \sum_{j=1}^q b_j \varepsilon_{t-j} + \varepsilon_t \end{aligned}$$

dengan $a_1, a_2, \dots, a_p, b_1, b_2, \dots, b_q \in \mathbb{R}$, ε_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

$$D(B) = (1 - a_1 B - a_2 B^2 - \dots - a_p B^p)$$

$$C(B) = (1 + b_1 B + b_2 B^2 + \dots + b_q B^q)$$

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

MODEL AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTIC (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

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_a \varepsilon_{t-a}^2 = \alpha_0 + \sum_{i=1}^a \alpha_i \varepsilon_{t-i}^2$$

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 σ_t^2 akan menjadi konstanta α_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 ε_t , yakni $P(\varepsilon_t > x)$ selalu lebih tebal dari distribusi normal. Dengan kata lain, fungsi *shock* ε_t dari model bersyarat Gaussian ARCH(1) akan membangkitkan lebih banyak kejadian ekstrem dibandingkan dengan proses *white noise* biasa yang berdistribusi Gaussian.

MODEL GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTIC (GARCH)

Model GARCH dikembangkan [4]) dalam rangka untuk mengefisienkan ordo besar yang mungkin terjadi pada model ARCH

Definisi 4. Misalkan $\varepsilon_t = r_t - \mu_t$ yaitu *mean corrected log return*, ε_t dikatakan mengikuti model GARCH (a, b) apabila

$$\begin{aligned} \varepsilon_t &= \sigma_t v_t \text{ dan} \\ \sigma_t^2 &= \alpha_0 + \sum_{i=1}^b \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^a \beta_j \sigma_{t-j}^2 \end{aligned}$$

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 definisi 1, 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 [8]

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

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 EGARCH 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.

$$VaR_{(1-\alpha)} = -W_0 R^*$$


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

HASIL PENELITIAN

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]

UJI NORMALITAS 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 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 *return* IHSG.



Gambar 2 Data *Return* IHSG Periode 30 Juni 2010 sampai 1 Juli 2015

Dari gambar 2 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 λ optimal adalah 0,3079685. Hasil transformasi telah berbentuk distribusi normal, ditunjukkan dengan hasil $p\text{-value} = 0.4179 > 5\%$.

UJI STASIONERITAS

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 *return* telah stasioner.

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 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 (≥ 1) yang keluar garis batas interval.

PEMILIHAN MODEL ARIMA

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 1.


Tabel 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)
a₁	√	√			√	√	X	X	√
a₂		√				X		X	√
a₃									√
a₄									√
a₅									√
b₁			√	√	√	√	√	X	
b₂				√			√	√	
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	-3112.86	-3112.34	-3115.63	-3114.4	-3009.73
SBC/ BIC	-2729.08	-2890.46	-3071.58	-3100.28	-3097.54	-3091.92	-3095.21	-3088.87	-2979.09

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; α=2,5%) untuk seluruh koefisien serta berdasarkan nilai RMSE, AIC, dan BIC yang paling minimum yang didukung dengan prinsip kesederhanaan pemodelan.

PENGUJIAN EFEK ARCH/GARCH



Gambar 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%.

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 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 **				
	$\sigma_t^2 = 0.227012 + 0.261899 \varepsilon_{t-1} + 0.004391 + 0.061231\varepsilon_{t-1}^2$								
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 ***	0.00483 Pr(> t) =0.8717	0.0592 Pr(> t) =0.077		
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) =0.0383 *	0.0306 Pr(> t) =0.001 ***			0.9352 Pr(> t) =0.000 ***	
	$\sigma_t^2 = 0.224 + 0.24924 \varepsilon_{t-1} + 0.00016 + 0.0306\varepsilon_{t-1}^2 + 0.9352 \sigma_{t-1}^2$								
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 ***
	$\sigma_t^2 = 0.224 + 0.25 \varepsilon_{t-1} + 0.0002 + 0.0527\varepsilon_{t-1}^2 + 0.817 \sigma_{t-2}^2$								

UJI ARCH LINEAR MODEL

Dari tabel 2 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 $p\text{-value} < 0,05$ 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.

UJI KORELASI SERIAL UNTUK RESIDUAL

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 χ^2 ataupun dari plot fungsi autokorelasi dan autokorelasi parsial dari residual kuadrat terstandarisasi. Korelasi serial merupakan ukuran keeratan hubungan antara residual kuadrat dengan data sebenarnya.

Dari tabel 4.2 dapat dirangkum hasil

- model (ARCH(1) tidak terdapat korelasi serial dalam residual kuadrat pada tingkat signifikansi 5%.
- model GARCH(1,1) tidak terdapat korelasi serial dalam residual kuadrat pada tingkat signifikansi 5%.
- 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).

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 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), α_1 , α_2 , dan α_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), ω , dan β_1 tidak signifikan	1552.802	-2.5341	-2.5048	-2.5342	-2.5231
GARCH(2,1)	Koefisien MA(2), ω , α_1 , dan α_2 tidak signifikan	1551.711	-2.5323	-2.5030	-2.5324	-2.5213
GARCH(2,2)	Koefisien MA(2), ω , α_1 , α_2 , dan β_1 tidak signifikan	1552.802	-2.5325	-2.4990	-2.5325	-2.5199

Memperhatikan tabel 3, tercermin beberapa model relatif optimal dalam memodelkan data *return* IHSG. 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.

PERAMALAN

Peramalan yang dilakukan adalah mencari nilai perkiraan dan prediksi dari *mean* dan variansi dengan model terbaik yang telah diperoleh. Nilai Ramalan harga IHSG dengan model GARCH(1,1) untuk 10 periode berikutnya ditunjukkan dalam tabel 4.

Tabel 4 Peramalan Harga Model GARCH(1,1)

Periode	Data Peramalan	Sigma Peramalan	Return IHSG	IHSG	Sigma
1223	0,2212	0,06324	0,007455236	4988,97136	0,000127855
1224	0,2235	0,06342	0,007709897	5078,329877	0,000129041
1225	0,2241	0,06359	0,007777308	5170,09134	0,000130167
1226	0,2241	0,06376	0,007777308	5263,510862	0,000131313
1227	0,2241	0,06393	0,007777308	5358,618402	0,000132441
1228	0,2241	0,06408	0,007777308	5455,444461	0,000133452
1229	0,2241	0,06423	0,007777308	5554,020091	0,000134469
1230	0,2241	0,06438	0,007777308	5654,376906	0,000135492
1231	0,2241	0,06452	0,007777308	5756,54709	0,000136451
1232	0,2241	0,06466	0,007777308	5860,563411	0,000137415

PERHITUNGAN VALUE AT RISK (VaR)

Dalam menghitung VaR, yang perlu dilakukan pertama kali adalah mengasumsikan dana yang dialokasikan untuk investasi. Didapatkan bahwa untuk periode 1 hari ke depan dari tanggal 1 Juli 2015 diprediksi dengan model GARCH(1,1), bahwa kerugian maksimum yang dapat ditoleransi investor dengan nilai investasi Rp 500.000.000,00 untuk tingkat kepercayaan 95% adalah Rp Rp 3.622.420,50.

PENUTUP

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

1. Hasil peramalan volatilitas nilai IHSG dengan menggunakan model GARCH(1,1) diperoleh nilai *log likelihood* yaitu 1551.711 dengan nilai kriteria informasi AIC = -2.5340; BIC = -2.5088; SIC = -2.5340; dan HQIC = -2.5245. Model ini terpilih menjadi model terbaik karena mendapat nilai *log likelihood* yang paling besar dengan nilai kriteria informasi paling minimum.
2. Nilai VaR pergerakan nilai IHSG apabila diketahui besar investasi Rp 500.000.000,00 untuk tingkat kepercayaan 95% untuk satu periode ke depan menggunakan model GARCH(1,1) adalah Rp 3.622.420,50.

Hasil analisis pergerakan nilai IHSG menggunakan model GARCH 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 diantaranya adalah model EGARCH (*Exponential GARCH*), T-GARCH (*Threshold-GARCH*), APARCH (*Asymmetric Power ARCH*).

DAFTAR PUSTAKA

- [1]. Zvie Bodie, A. K. A. J. M. *Investments*. New York: McGraw-Hill; 2006.
- [2]. Mehmet, A. *Analysis of Turkish Financial Market with Markov Regime Switching Volatility Models*. Ankara: The Middle East Technical University; 2008.
- [3]. Engle, R. The Use of ARCH/GARCH Models in Applied Econometrics. *Journal of Econometric Prespectiv*.1982;pp. 157-168.
- [4]. Bollerssev, T. Generalized Autoregressive Conditional Heteroscedasticity. *J. Econometrics*.1986; pp. 307-327.
- [5]. Nelson, D. B. Conditional Heteroscedasticity in Assets Returns:A New Approach. *Econometrica*. 1991; Vol. 59, pp. 347-370.
- [6]. Risk Metrics TM. *Technical Document, 4 th Edition*. New York: JP Morgan/Reuters;1996.
- [7]. Best, P. *Implementatinng Value at Risk..* West Sussex: John Wiley and Sons,Ltd;1998.
- [8]. Tagliafichi, R. A. *The Estimation of Market VaR Using GARCH Models and A Heavy Tail Distributions*, s.l.: Faculty of Economics University of Buenos Aires Argentina'; 2003.
- [9]. <http://www.yahoo.finance.com/>. (diakses 4 Agustus 2015)