

## **MODEL GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY IN MEAN UNTUK MERAMALKAN VOLATILITAS RETURN SAHAM**

**Syarifah Zela Hafizah, Dadan Kusnandar, Shantika Martha**

### **INTISARI**

*Volatilitas menunjukkan fluktuasi pergerakan harga saham. Semakin tinggi volatilitas maka semakin tinggi pula kemungkinan mengalami keuntungan dan kerugian. Data time series yang sering memiliki volatilitas yang tinggi adalah data keuangan. Data time series di bidang keuangan sering memiliki sifat volatility clustering atau sering disebut sebagai kasus heteroskedastisitas. Pada umumnya, pemodelan data time series harus memenuhi asumsi varian konstan (homoskedastisitas). Untuk mengatasi masalah heteroskedastisitas, model time series yang dapat digunakan adalah ARCH/GARCH. Model GARCH merupakan pengembangan dari model ARCH yang dapat digunakan untuk menggambarkan sifat dinamik volatilitas dari data. Salah satu bentuk pengembangan dari model GARCH adalah Generalized Autoregressive Conditional Heteroscedasticity in Mean (GARCH-M). Tujuan dari penelitian ini adalah untuk mengimplementasikan model GARCH-M pada peramalan volatilitas return saham. Data yang digunakan dalam penelitian ini adalah return penutupan harga saham mingguan S&P 500 dari September 2013 sampai Juni 2019. Model terbaik yang digunakan untuk peramalan volatilitas pada return harga saham S&P 500 adalah MA (1) GARCH (1,1)-M.*

**Kata Kunci:** saham, volatilitas, GARCH-M

### **PENDAHULUAN**

Data *time series* terutama data keuangan seperti indeks harga saham sering kali memiliki volatilitas yang tinggi. Volatilitas yang tinggi ditunjukkan oleh suatu tahap dimana fluktuasinya relatif tinggi, kemudian diikuti fluktuasi yang rendah dan kembali tinggi. Data demikian cenderung memiliki rata-rata dan varians yang tidak konstan. Adanya volatilitas yang tinggi sulit untuk dilakukan estimasi dan prediksi pergerakan nilainya di bidang keuangan. Oleh karena itu, peramalan volatilitas memiliki pengaruh yang penting dalam pengambilan keputusan investasi. Hal itu disebabkan karena apabila volatilitas tinggi, maka ketidakpastian *return* saham yang diperoleh juga tinggi.

Volatilitas yang tinggi yang terdapat pada data keuangan mengakibatkan terjadinya *volatility clustering* atau sering disebut sebagai kasus heteroskedastisitas. Tetapi pada umumnya pemodelan data *time series* harus memenuhi asumsi varian konstan (homoskedastisitas). Maka dari itu, untuk mengatasi masalah heteroskedastisitas, model *time series* yang dapat digunakan adalah *Autoregressive Conditional Heteroscedasticity* (ARCH), *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH), dan *Generalized Autoregressive Conditional Heteroscedasticity in Mean* (GARCH-M). GARCH-M merupakan pengembangan model GARCH. Model GARCH-M menjelaskan bahwa *return* suatu saham tergantung pada volatilitas. Pada model ini, didapatkan nilai *risk premium* yang dapat dijadikan pertimbangan dalam investasi.

Penelitian ini bertujuan untuk mengimplementasikan model GARCH-M pada peramalan volatilitas *return* saham. Langkah analisis yang digunakan untuk mengaplikasikan GARCH-M untuk peramalan volatilitas *return* saham, yang pertama adalah menghitung nilai *return* harga saham. Kemudian menguji stasioneritas data *return* dengan uji ADF, jika data stasioner dilanjutkan dengan mengidentifikasi model *mean* dengan model ARIMA. Setelah didapat model ARIMA, diuji heteroskedastisitasnya. Apabila terdapat heteroskedastisitas, dilanjutkan dengan mengidentifikasi model varians dengan model GARCH-M. Terakhir melakukan peramalan volatilitas dengan GARCH-M.

### ANALISIS TIME SERIES

Metode yang digunakan untuk menentukan model yang sesuai pada data *time series* adalah metode Box-Jenkins. Metode tersebut dikenal dengan model *Autoregressive Moving Average* (ARMA) untuk data stasioner dan *Autoregressive Integrated Moving Average* (ARIMA) untuk data non stasioner. Model ARMA merupakan gabungan dari metode AR (*Autoregressive*) dan MA (*Moving Average*).

*Autoregressive* adalah suatu bentuk regresi tetapi bukan yang menghubungkan variabel tak bebas, melainkan menghubungkan nilai-nilai sebelumnya pada *time lag* (selang waktu) yang bermacam-macam. Model *Autoregressive* dengan orde  $p$  dinotasikan dengan AR ( $p$ ). Pada model AR,  $X_t$  dipengaruhi oleh  $p$  amatan yang lalu dan dapat dituliskan sebagai [1,2]:

$$X_t = \omega_1 X_{t-1} + \omega_2 X_{t-2} + \dots + \omega_p X_{t-p} + \varepsilon_t$$

*Moving Average* dengan orde  $q$  dinotasikan dengan MA ( $q$ ). *Moving Average* merupakan proses dimana  $X_t$  dihasilkan dari *forecast error* beberapa periode sebelumnya. Model MA dapat didefinisikan sebagai [1,2]:

$$X_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Model *Autoregressive Moving Average* (ARMA) merupakan suatu kombinasi dari model AR dan MA. Secara umum model ARMA ( $p, q$ ) adalah sebagai berikut [1,2]:

$$X_t = \sum_{i=1}^p \omega_i X_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t$$

Pada umumnya pemodelan data *time series* harus memenuhi asumsi varians *error* yang konstan (homoskedastisitas). Namun data *time series* pada sektor keuangan sangat tinggi volatilitasnya dan sering terjadi heteroskedastisitas. Untuk mengatasi masalah heteroskedastisitas, maka digunakan model ARCH. Model *Autoregressive Conditional Heteroscedastic* (ARCH) adalah model yang digunakan untuk mengatasi heteroskedastisitas dalam *time series*. Bentuk umum model ARCH ( $p$ ) [3]:

$$\sigma_t^2 = a_0 + a_1 \varepsilon_{t-1}^2 + a_2 \varepsilon_{t-2}^2 + \dots + a_p \varepsilon_{t-p}^2$$

Bollerslev (1986) mengembangkan model ARCH. Model tersebut disebut dengan *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Model GARCH adalah salah satu model *time series* yang dapat digunakan untuk menggambarkan sifat dinamik volatilitas dari data. Penerapan model tersebut pada data historis akan membangkitkan perkiraan statistik volatilitas pada masa lalu, dimana dari data waktu ke waktu tersedia. Hal itu juga akan menimbulkan peramalan terhadap volatilitas dari sekarang sampai suatu titik di masa yang akan datang. Bentuk umum model GARCH ( $p, q$ ) [4]:

$$\sigma_t^2 = a_0 + a_1 \varepsilon_{t-1}^2 + \dots + a_p \varepsilon_{t-p}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_q \sigma_{t-q}^2$$

Salah satu pengembangan GARCH adalah GARCH *in mean* atau disingkat GARCH-M. Model GARCH-M terdapat varians atau standar deviasi di dalam persamaan *mean*. Hal ini dilakukan pada kasus-kasus tertentu, misalnya pada kondisi seorang investor yang menyenangi risiko. Investor yang ingin mendapatkan *risk premium* dari saham yang memiliki risiko tinggi, dapat menggunakan metode ini.

Model GARCH ( $p, q$ )-M dengan varians dapat dinyatakan dengan persamaan sebagai berikut [5]:  
*Mean Equation*:

$$y_t = \gamma x_t + c \sigma_t^2 + \varepsilon_t$$



---

Variance Equation:

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


## HASIL DAN PEMBAHASAN

Data yang digunakan dalam penelitian ini adalah data sekunder yaitu harga indeks saham S&P 500 mingguan jangka waktu September 2013 sampai Juni 2019. Untuk mengetahui pergerakan harga saham tersebut, diperoleh grafik harga saham adalah sebagai berikut:



**Gambar 1** Grafik Data Harga Saham S&P 500

Gambar 1 menunjukkan bahwa data harga saham S&P 500 mengalami *trend* yang naik. Terlihat adanya volatilitas yang sangat fluktuatif dari data, sehingga dapat disimpulkan secara subyektif bahwa terdapat volatilitas pada data. Karakteristik data yang dianalisis adalah data *return* harga saham penutupan S&P 500.



**Gambar 2** Grafik Data *Return* Harga Saham S&P 500

Pada Gambar 2 terlihat bahwa plot *return* saham S&P 500 telah stasioner. Hal ini terlihat dari rata-rata deret pengamatan di sepanjang waktu yang selalu konstan (berfluktuasi di sekitar nilai tengah).

Uji stasioner pada data *return* juga dilakukan dengan uji *Augmented Dickey Fuller* (ADF). Adapun hipotesis uji ADF yang digunakan adalah sebagai berikut:

$H_0$  : Data *return* tidak stasioner



$H_1$  : Data *return* stasioner

Jika nilai probabilitas kurang dari nilai  $\alpha = 0,05$  maka  $H_0$  ditolak.

**Tabel 1** Uji *Augmented Dickey Fuller* (ADF)

	<i>t-Statistic</i>	<i>Prob</i>
ADF Test	-20,35264	0,0000
Test critical value	1% level	-3,451146
	5% level	-2,870591
	10% level	-2,571663

Berdasarkan Tabel 1 nilai probabilitas uji ADF kurang dari  $\alpha$  yang berarti  $H_0$  ditolak, artinya data *return* telah stasioner. Hasil uji ADF mendukung kesimpulan bahwa data dapat dimodelkan dengan ARMA ( $p,q$ ).

**Gambar 3** Plot ACF Data Return**Gambar 4** Plot PACF Data Return

Berdasarkan Gambar 3 dan Gambar 4 model yang teridentifikasi adalah AR (1) dan MA (1) pada data *return* harga saham. Model kombinasi yang didapatkan yaitu AR (1), MA (1), dan ARMA (1,1).

Adapun hipotesis uji yang digunakan untuk menguji signifikansi parameter model adalah sebagai berikut:

$H_0$  : Parameter tidak signifikan dalam model

$H_1$  : Parameter signifikan dalam model

Jika nilai probabilitas kurang dari  $\alpha = 0,05$  maka  $H_0$  ditolak.

**Tabel 2** Estimasi dan Uji Signifikansi Parameter

Model	Parameter	Koefisien	Prob	Keputusan
AR (1)	$\omega_1$	-0,142739	0,0011	Signifikan
MA (1)	$\theta_1$	-0,153824	0,0004	Signifikan
ARMA (1,1)	$\omega_1$	0,734785	0,0000	Signifikan
	$\theta_1$	-0,863848	0,0000	Signifikan

Berdasarkan Tabel 2 semua nilai probabilitas kurang dari  $\alpha$  yang berarti  $H_0$  ditolak, artinya parameter signifikan dalam model.

Selanjutnya dilakukan verifikasi model ARMA yang dilakukan untuk mengetahui residual apakah mengandung autokorelasi atau *white noise*. Adapun hipotesis uji yang digunakan adalah sebagai berikut:

$H_0$  : Residual *white noise*

$H_1$  : Residual tidak *white noise*

Jika nilai probabilitas kurang dari  $\alpha (0,05)$  maka  $H_0$  ditolak.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.004	-0.004	0.0041	
		2 -0.041	-0.041	0.5336	0.465
		3 -0.095	-0.095	3.3937	0.183
		4 0.028	0.025	3.6393	0.303
		5 -0.071	-0.079	5.2338	0.264
		6 -0.051	-0.059	6.0550	0.301
		7 -0.072	-0.076	7.7188	0.259
		8 0.078	0.058	9.6971	0.206
		9 -0.028	-0.042	9.9466	0.269
		10 -0.090	-0.105	12.586	0.182
		11 0.012	0.016	12.630	0.245
		12 0.004	-0.030	12.635	0.318
		13 -0.088	-0.109	15.185	0.231
		14 0.021	0.021	15.327	0.287
		15 -0.062	-0.087	16.611	0.278

Gambar 5 Uji Autokorelasi Residual AR (1)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.005	0.005	0.0078	
		2 -0.019	-0.020	0.1281	0.720
		3 -0.096	-0.096	3.0806	0.214
		4 0.024	0.025	3.2719	0.352
		5 -0.075	-0.079	5.0518	0.282
		6 -0.050	-0.058	5.8552	0.321
		7 -0.074	-0.073	7.6166	0.268
		8 0.074	0.057	9.3906	0.226
		9 -0.029	-0.042	9.6710	0.289
		10 -0.089	-0.106	12.231	0.201
		11 0.008	0.015	12.253	0.268
		12 0.002	-0.028	12.254	0.345
		13 -0.089	-0.110	14.865	0.249
		14 0.020	0.022	15.000	0.307
		15 -0.064	-0.085	16.357	0.292

Gambar 6 Uji Autokorelasi Residual MA (1)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.039	-0.039	0.4732	
		2 0.062	0.060	1.6836	
		3 -0.038	-0.033	2.1363	0.144
		4 0.081	0.075	4.2296	0.121
		5 -0.039	-0.030	4.7241	0.193
		6 -0.010	-0.023	4.7552	0.313
		7 -0.060	-0.053	5.9195	0.314
		8 0.087	0.078	8.3619	0.213
		9 -0.023	-0.008	8.5299	0.288
		10 -0.080	-0.094	10.596	0.226
		11 0.015	0.025	10.672	0.299
		12 0.008	0.003	10.693	0.382
		13 -0.088	-0.092	13.220	0.279
		14 0.036	0.046	13.657	0.323
		15 -0.066	-0.054	15.086	0.302

Gambar 7 Uji Autokorelasi Residual ARMA (1,1)

Diketahui nilai probabilitas lebih dari  $\alpha$  yang berarti  $H_0$  diterima, artinya residual *white noise*.

Selanjutnya dilakukan pemilihan model terbaik model ARMA dengan melihat nilai SIC dan BIC terkecil.

Tabel 3 Pemilihan Model Terbaik

Model	SIC	BIC
AR (1)	-5,2004	-8,050
MA (1)	<b>-5,2017</b>	<b>-8,052</b>
ARMA (1,1)	-5,1971	-8,042

Berdasarkan Tabel 3 maka diperoleh model terbaik yaitu model MA (1) yang memiliki nilai SIC dan BIC terkecil.

Selanjutnya dilakukan uji heteroskedastisitas atau menguji apakah model mengandung efek heteroskedastisitas atau tidak. Adapun hipotesis uji yang digunakan adalah sebagai berikut:

$$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_m = 0$$


$$H_1: \alpha_1 = \alpha_2 = \dots = \alpha_m \neq 0$$

Jika nilai probabilitas kurang dari  $\alpha = 0,05$  maka  $H_0$  ditolak.


Tabel 4 Uji Heteroskedastisitas MA (1)

F-statistic	15,68244	Prob. F (1,310)	0,0001
Obs*R-Squared	15,02360	Prob. Chi-Square (1)	0,0001

Berdasarkan Tabel 4 nilai probabilitas kurang dari  $\alpha$  (0,05) yang berarti  $H_0$  ditolak. Artinya terdapat heteroskedastisitas pada residual atau mengandung efek ARCH/GARCH.



**Gambar 8** Plot ACF Residual Kuadrat



**Gambar 9** Plot PACF Residual Kuadrat

Model MA (1) selanjutnya dapat dimodelkan ke dalam model GARCH-M dan dibatasi hanya sampai lag kedua, yaitu MA (1) GARCH (1,1)-M; MA (1) GARCH (1,2)-M; MA (1) GARCH (2,1)-M; MA (1) GARCH (2,2)-M.

Adapun hipotesis uji yang digunakan untuk menguji signifikansi parameter model adalah sebagai berikut:

$H_0$  : Parameter tidak signifikan dalam model

$H_1$  : Parameter signifikan dalam model

Jika nilai probabilitas kurang dari  $\alpha$  maka  $H_0$  ditolak. Setelah dilakukan estimasi dan uji signifikansi terhadap semua model, didapat model yang memiliki parameter yang signifikan pada semua komponennya adalah model MA (1) GARCH (1,1)-M seperti pada Tabel 5.

**Tabel 5** Estimasi dan Uji Signifikansi MA (1) GARCH (1,1)-M

Model	Parameter	Koefisien	Prob.	Keputusan
MA (1) GARCH (1,1)-M	$c$	12,77171	0,0333	Signifikan
	$\theta_1$	-0,134909	0,0349	Signifikan
	$\alpha_0$	0,0000287	0,0374	Signifikan
	$\alpha_1$	0,127150	0,0244	Signifikan
	$\beta_1$	0,761201	0,0000	Signifikan

Selanjutnya dilakukan verifikasi model GARCH (p,q)-M yang dilakukan untuk mengetahui apakah residual mengandung autokorelasi atau *white noise*. Adapun hipotesis uji yang digunakan adalah sebagai berikut:

$H_0$  : Residual *white noise*

$H_1$  : Residual tidak *white noise*

Jika nilai probabilitas kurang dari  $\alpha$  (0,05) maka  $H_0$  ditolak. Nilai probabilitas pada Tabel 5 lebih dari  $\alpha$  yang berarti  $H_0$  diterima, artinya residual *white noise*.

Selanjutnya dilakukan kembali uji heteroskedastisitas model MA (1) GARCH (1,1)-M.

**Tabel 6** Uji Heteroskedastisitas MA (1) GARCH (1,1)-M

F-statistic	0,450326	Prob. F (1,400)	0,5026
Obs*R-Squared	0,452069	Prob. Chi-Square (1)	0,5014

Berdasarkan Tabel 6, nilai probabilitas lebih dari  $\alpha$  yang berarti  $H_0$  diterima, artinya tidak terdapat heteroskedastisitas pada residual.

Langkah terakhir yang dilakukan adalah meramalkan volatilitas untuk beberapa periode selanjutnya dengan menggunakan model yang sesuai yaitu MA (1) GARCH (1,1)-M

$$\hat{y}_t = -0,134909\varepsilon_{t-1} + 12,77171\sigma_t^2$$

dengan

$$\sigma_t^2 = 0,0000287 + 0,127150\varepsilon_{t-1}^2 + 0,761201\sigma_{t-1}^2$$

Hasil peramalan volatilitas pada *return* harga saham S&P 500 menggunakan model MA (1) GARCH (1,1)-M untuk lima minggu ke depan adalah sebagai berikut:

**Tabel 7** Hasil Peramalan Volatilitas

Minggu ke-	Peramalan Volatilitas
1	0,01305
2	0,01342
3	0,01373
4	0,01401
5	0,01425

## KESIMPULAN

Penerapan pemodelan GARCH-M pada studi kasus harga *return* saham mingguan S&P 500 diperoleh model terbaik MA (1) GARCH (1,1)-M. Model yang digunakan untuk meramalkan volatilitas *return* saham adalah:

$$\hat{y}_t = -0,134909\varepsilon_{t-1} + 12,77171\sigma_t^2$$

dengan

$$\sigma_t^2 = 0,0000287 + 0,127150\varepsilon_{t-1}^2 + 0,761201\sigma_{t-1}^2$$

Dengan model tersebut diperoleh estimasi volatilitas selama lima minggu kedepan. Nilai ramalan volatilitas yang dihasilkan berkisar 0,01305 sampai 0,01425. Nilai tersebut memiliki selisih yang relatif kecil, maka dapat dikatakan volatilitas tergolong rendah, sehingga nilai *return* dan risikonya juga rendah.

## DAFTAR PUSTAKA

- [1]. Lo, M.S. *Generalized Autoregressive Conditional Heteroscedastic Time Series Model*. Simon Fraser University. 2003.
- [2]. Wei, W.W.S. *Time Series Analysis, Univariate and Multivariate Methods*. Redwood City: Addison-Wesley Publishing Company, Inc. 2006.
- [3]. Desvina, A. P dan Nadya, R. Penerapan metode ARCH/GARCH dalam peramalan Indeks Harga Saham Sektorial. *Jurnal Sains Matematika dan Statistika*. 2016. **2** (1): 1-10.
- [4]. Hartati dan Imelda, S. Aplikasi GARCH dalam Mengatasi Volatilitas pada Data Keuangan. *Jurnal Matematika*. 2017. **7** (2): 107-118.
- [5]. Ekananda, M. *Analisis Data Time Series*. Jakarta: Mitra Wacana Media. 2014.

SYARIFAH ZELA HAFIZAH : Jurusan Matematika, FMIPA UNTAN, Pontianak  
syarifahzela@gmail.com

DADAN KUSNANDAR : Jurusan Matematika, FMIPA UNTAN, Pontianak  
dkusnand@untan.ac.id

SHANTIKA MARTHA : Jurusan Matematika, FMIPA UNTAN, Pontianak  
shantika.martha@math.untan.ac.id

---