

Penerapan Model ARCH/GARCH untuk Memprediksi Harga Saham Perusahaan Tokai Carbon

Puspa Faydian¹, Amsal Esa Hasana², Muhammad Irfan³, Teguh Ammar Taqiyuddin⁴

^{1,2,3,4} Prodi Statistika, Universitas Padjadjaran

Jl. Raya Bandung Sumedang KM.21, Hegarmanah, Jatinangor, Kabupaten Sumedang, Jawa Barat 45363

Email: puspa19004@mail.unpad.ac.id¹, amsal19001@mail.unpad.ac.id², muhammad18011@mail.unpad.ac.id³, teguh18001@mail.unpad.ac.id⁴

*Korespondensi penulis : muhammad18011@mail.unpad.ac.id

Abstrak

Data harga saham historis adalah rangkuman tren harga saham individual emiten. Penelitian ini membahas tentang prediksi data historis saham Tokai Carbon, dengan 60 data mulai dari Januari 2016 sampai Desember 2020. Tujuan penelitian ini adalah untuk memodelkan data historis saham Tokai Carbon melalui model ARCH/GARCH. Model GARCH (0, 1) adalah model yang paling Tepat untuk memprediksi harga saham Tokai Carbon pada penelitian ini. Nilai MAPE menunjukkan persentase yang rendah yakni sebesar 4,949972% yang mengindikasikan metode ARCH/GARCH sangat baik dalam memprediksi harga saham Tokai Carbon. Pembentukan model dilakukan untuk memprediksi data saham Tokai Carbon untuk 7 bulan ke depan, yakni mulai Januari 2021 hingga Juli 2021.

Kata Kunci: ARCH/GARCH, Prediksi, Tokai Carbon

Abstract

Historical stock price data is a summary of the stock price trends of individual issuers. This study discusses the historical data forecasting of Tokai Carbon's stock, with 60 data from January 2016 to December 2020. The purpose of this study is to model the historical data of Tokai Carbon's stock through the ARCH/GARCH model. The GARCH (0, 1) model is the most appropriate model to predict the stock price of Tokai Carbon in this study. MAPE's value represents a low percentage of 4.949972% which indicates the ARCH/GARCH method is very good at predicting Tokai Carbon's share price. The formation of a model was carried out to predict Tokai Carbon stock data for the next 7 months, namely from January 2021 to July 2021.

Keywords: ARCH/GARCH, Prediction, Tokai carbon

1. Pendahuluan

Menurut [1], saham merupakan investasi, didukung dengan pandangan teori ekonomi yang menjelaskan bahwa saham adalah salah satu jenis investasi. Prinsip berinvestasi adalah meningkatkan uang yang kita miliki saat ini. Saham bukanlah cara untuk memperkaya seseorang tanpa modal. Dengan kata lain, saham merupakan bentuk sumbangan modal dalam sebuah perusahaan. Data historis saham merangkum pergerakan harga saham individu dari suatu emiten tertentu.

Data deret waktu dengan varians yang tidak tetap disebut data deret waktu dengan heteroskedastisitas bersyarat (*conditional heteroscedastic*) [2]. Dalam hal ini, diperlukan metode prediksi yang baik dan tepat untuk mengatasi kemungkinan variabilitas data. Metode yang digunakan harus dapat memodelkan sebagian besar data dengan tetap mempertahankan heteroskedastisitas data. Menurut Bollerslev, data yang mengandung heteroskedastisitas dapat dianalisis menggunakan metode *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH).

Perusahaan tidak lepas jadi objek peneliti untuk diukur dan diramal tingkat volatilitasnya agar dapat memperdiksi harga saham kedepannya akan seperti apa. [3] menggunakan model GARCH untuk memodelkan dan meramal penutupan harga saham PT. Telkom. Begitu juga dengan [4] menguji volatilitas *assymetric* dari nilai tukar menggunakan APARCH.

Dari penelitian-penelitian tersebut maka dianggap model ARCH dapat diterapkan untuk memprediksi harga saham pada Perusahaan Tokai Carbon dengan menggunakan data historis untuk prediksi. Data yang digunakan berjumlah 60 yang merupakan data historis saham Tokai Carbon bulanan mulai Januari 2016 sampai Desember 2020.

2. Metode Penelitian

2.1. Landasan Teori

2.1.1. Saham

Surat yang menyatakan kepemilikan atas kekayaan perusahaan disebut dengan saham. Nilai suatu saham yang mencerminkan kekayaan perusahaan yang menerbitkannya, dan volatilitas saham dipengaruhi oleh penawaran dan permintaan pasar saham (pasar sekunder) disebut dengan harga saham. Harga saham naik ketika lebih banyak investor yang ingin membeli atau menahan saham, dan turun ketika lebih banyak investor yang ingin menjual saham tersebut [5]. Volatilitas mengacu pada perubahan fluktuasi acak harga saham, yang bisa tinggi dan juga rendah dalam beberapa kasus. Oleh karena itu, investor membutuhkan alat atau metode untuk mengukur volatilitas untuk dapat memprediksi pergerakan harga saham di masa mendatang [6].

2.1.2. Prediksi dan Deret Waktu

Prediksi adalah metode pengambilan keputusan yang memperkirakan suatu nilai di masa depan berdasarkan faktor data masa lalu dan masa kini. Deret waktu (*time series*) merupakan urutan data pengamatan yang terjadi berdasarkan waktu pada interval waktu tertentu. Analisis deret waktu adalah salah satu teknik statistik yang diterapkan untuk

memprediksi struktur probabilitas. Struktur dengan kondisi yang akan terjadi di masa depan dalam konteks pengambilan keputusan [7].

2.1.3. Uji Stasioner Data

Analisis deret waktu dapat dengan mudah menentukan apakah suatu data deret waktu itu stasioner dalam rata-rata dan variansnya [8]. Uji kestasioneran data dapat dilakukan dengan beberapa cara, diantaranya:

1. Pola Deret Waktu

Apabila rata-rata dari waktu ke waktu bernilai konstan, maka data tersebut cenderung stasioner jika tidak maka perlu dilakukan *differencing*. Kemudian apabila varians bernilai konstan, maka data tersebut cenderung stasioner jika terlihat naik turun, maka perlu dilakukan transformasi terhadap data agar data stasioner dalam varians.

2. Uji *Unit Root*

Uji ini berfungsi untuk memeriksa apakah data tersebut sudah stasioner atau tidak secara lebih jelas. Umumnya, terdapat tiga uji yang biasa dilakukan dalam uji *unit root*, yaitu uji *Augmented Dickey-Fuller (ADF)*, *Philps Perron (PP)*, *Kwiatkowski Phillips Schmidt Shin (KPSS)* [9].

2.1.4. Model Deret Waktu

Model deret waktu yang tepat akan membuat prediksi akurat. Setiap model memiliki metode masing-masing, dan berdasarkan karakteristik tersebut dapat dibuat tolok ukur yang menentukan model yang sesuai untuk data. Beberapa model deret waktu tersebut adalah [10]:

1. Model $AR(p)$

Deret waktu \bar{Y}_t adalah proses *AR (Autoregressive)* orde p atau $AR(p)$, yang dapat dinyatakan dengan:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t \quad (1)$$

Artinya, \bar{Y}_t merupakan kombinasi linier p buah nilai-nilai sebelumnya ditambah dengan kekeliruan pada waktu t . Variabel kekeliruan e_t diasumsikan saling bebas terhadap $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ dan berdistribusi normal dengan rata-rata 0 dan varians σ^2 .

2. Model $MA(q)$

Model *MA (Moving Average)* orde q adalah deret \bar{Y}_t yang dibentuk dengan menghitung *error* pada waktu t dan *error* sebelumnya yang diberi bobot, sehingga dapat dinyatakan sebagai:

$$Y_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (1)$$

3. Model $ARMA(p,q)$

Model *ARMA (Auto Regressive Moving Average)* orde p dan q proses *time series* yang dibangun dari penggabungan $AR(p)$ dan $MA(q)$ dengan persamaan sebagai berikut:

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (3)$$

4. Model ARIMA(p,d,q)

Model ARIMA(p,d,q) merupakan kombinasi dari model ARMA(p,q) yang telah dilakukan *differencing* sehingga data telah stasioner. Model yang terbentuk dinyatakan sebagai:

$$\Phi_p(B)(1-B)^d Y_t = \theta_q(B)e_t \quad (4)$$

2.1.5. Metode ARCH-GARCH

Kerangka estimasi yang memperhitungkan adanya heteroskedastisitas dikembangkan oleh Engle (1982). Oleh karena itu, estimasi parameter dapat dilakukan dengan presisi yang lebih tinggi. *Autoregressive Conditional Heteroscedastic* (ARCH) adalah kerangka estimasi untuk menghitung heteroskedastisitas. Model ini dikembangkan oleh Bollerslev (1986) dan Taylor (1986) menjadi model *Generalized Autoregressive Conditional Heteroscedastic* (GARCH) [11]. Bentuk umum dari model ARCH adalah sebagai:

$$\sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \alpha_2 e_{t-2}^2 + \dots + \alpha_p e_{t-p}^2 \quad (5)$$

Bollerslev (1986) dan Taylor (1986) mengembangkan metode ARCH dalam bentuk model GARCH yang mempunyai bentuk persamaan umum sebagai:

$$\sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \alpha_2 e_{t-2}^2 + \dots + \alpha_p e_{t-p}^2 + \lambda_1 \sigma_{t-1}^2 + \dots + \lambda_q \sigma_{t-q}^2 \quad (6)$$

dengan

- σ_t^2 : Varian pada periode t
- a_0 : Konstanta
- $\alpha_1, \dots, \alpha_p$: Parameter ARCH
- e_{t-1}^2 : Residual pada periode t-1, i=1, 2, ..., p
- σ_{t-1}^2 : Varian periode t-1, t=1, 2, ..., q

2.1.6. Estimasi Parameter ARCH-GARCH

Model dari ARCH(q) dan GARCH(p,q) merupakan non-linier, maka metode kemungkinan maksimum (*maximum likelihood*) digunakan untuk mengestimasi parameter model ARCH-GARCH.

Untuk rumus ARCH, distribusi probabilitasnya adalah:

$$P(\sigma_t^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \left[-\frac{1}{2}(\sigma_t^2 - \alpha_0 + \alpha_1 e_{t-1}^2)^2 \right] \quad (7)$$

Fungsi *Likelihood* merupakan produk dari setiap peluang kejadian pada n buah pengamatan, maka dapat dituliskan sebagai berikut.

$$LF = \frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}} \exp \left[-\sum_{t=1}^n \left(\frac{\sigma_t^2 - \alpha_0 + \alpha_1 e_{t-1}^2}{2\sigma^2} \right)^2 \right] \quad (8)$$

Pada persamaan di atas, nilai fungsi *likelihood* (LF) dimaksimumkan sedemikian sehingga probabilitas σ_t^2 bernilai setinggi mungkin. Hal tersebut dilakukan dengan menurunkan fungsi *likelihood* terhadap masing-masing parameter, lalu disamadengankan nol. Persamaan LF diubah menjadi bentuk logaritma natural (*ln*) untuk memudahkan perhitungan. Memaksimalkan nilai fungsi *ln LF* akan sama dengan memaksimalkan fungsi LF.

$$\ln LF = -n \ln \sigma^2 - \frac{n}{2} \ln(2\pi) - \frac{1}{2} \sum_{t=1}^n \frac{(\sigma_t^2 - \alpha_0 + \alpha_1 e_{t-1}^2)^2}{\sigma^2} \quad (9)$$

Selanjutnya, persamaan (4) terhadap α_0, α_1 sehingga didapat:

$$\frac{\partial \ln LF}{\partial \alpha_0} = -\frac{1}{\sigma^2} \sum_{t=1}^n (\sigma_t^2 - \alpha_0 + \alpha_1 e_{t-1}^2) (e_{t-1}^2) \quad (10)$$

Buat Persamaan (4) dan (5) sama dengan nol, sehingga diperoleh rumusan dalam mencari taksiran untuk kemungkinan maksimum.

$$\frac{1}{\sigma^2} \sum_{t-1}^n (\sigma_t^2 - \alpha_0 + \alpha_1 e_{t-1}^2)(e_{t-1}^2) = 0 \quad (11)$$

Sehingga didapat:

$$\sum_{t-1}^n \sigma_t^2 e_{t-1}^2 = (\alpha_0 \sum_{t-1}^n e_{t-1}^2 + \alpha_1 \sum_{t-1}^n e_{t-1}^4) \quad (12)$$

Sehingga didapat nilai estimasi parameter

$$\alpha_0 = \overline{\sigma_t^2} - \alpha_1 \overline{e_{t-1}^2} \quad (13)$$

$$\alpha_1 = \frac{\sum_{t-1}^n \sigma_t^2 e_{t-1}^2 - (\sum_{t-1}^n \sigma_t^2 e_{t-1}^2)(\sum_{t-1}^n e_{t-1}^2/n)}{(\sum_{t-1}^n e_{t-1}^2) + ((\sum_{t-1}^n e_{t-1}^2)^2/n)} \quad (14)$$

2.1.7. Nilai Ketepatan Prediksi Mean Absolute Percentage Error (MAPE)

Menurut [12], $\alpha_0 \sum_{t-1}^n e_{t-1}$ Mean Absolute Percentage Error (MAPE) diperoleh dengan menghitung kesalahan *absolute* untuk setiap periode kemudian dibagi dengan nilai aktual yang diamati selama periode tersebut. Nilai tersebut didapatkan dengan persamaan 15.

$$MAPE = \left(\frac{100\%}{n} \right) \sum_{t-1}^n \frac{|X_t - F_t|}{X_t} \quad (15)$$

dengan

X_t : Data aktual pada periode t

F_t : Nilai prediksi pada periode t

MAPE digunakan untuk mengevaluasi hasil prediksi dapat menghindari akurasi pengukuran terhadap besarnya nilai aktual dan nilai prediksi. Kriteria nilai MAPE menurut [13] ditunjukkan pada Tabel 1 berikut.

Tabel 1. Kriteria nilai MAPE

Nilai MAPE	Kriteria
< 10%	Sangat baik
10% - 20%	Baik
20% - 50%	Cukup
> 50%	Buruk

2.2. Metodologi Penelitian

Data yang digunakan untuk penelitian ini bersumber dari website <https://id.investing.com/equities/tokai-carbon-co.-ltd.-historical-data> yang merupakan data ringkasan fluktuasi harga saham perusahaan Tokai Carbon, dengan 60 data mulai dari Januari 2016 sampai Desember 2020. Pemodelan dan prediksi dilakukan dengan melibatkan seluruh data tanpa membagi data ke bagian training maupun testing. Analisis data dilakukan dengan metode ARCH-GARCH menggunakan software R. Langkah-langkah penerapan model ARCH-GARCH adalah sebagai berikut.

1. Uji Kestasioneran Data

Uji ini berfungsi dalam mengecek data telah stasioner atau belum. Proses *transformasi* dapat dilakukan apabila data belum stasioner dalam variansnya. Sedangkan proses differencing dilakukan apabila data belum stasioner dalam rata-ratanya.

2. Identifikasi Model
Melalui grafik deret waktu dan plot ACF PACF, serta uji unit root dapat menunjukkan kestasioneran data. Kombinasi model yang kemungkinan sesuai dengan prediksi dapat dilihat melalui ACF dan PACF.
3. Estimasi Parameter Model dan Pemilihan Model Terbaik
Lakukan estimasi parameter setelah terpilih beberapa model untuk memperoleh nilai koefisien yang signifikan dari model. Salah satu indikator kebaikan model adalah penggunaan AIC.
4. Diagnostik Model
Setelah mendapatkan model yang terbaik, kemudian dilakukan pengujian asumsi yang perlu dilakukan seperti normalitas dan juga whitenoise autokorelasi.
5. Uji ARCH-LM
Uji ARCH-LM berfungsi untuk mengecek keberadaan heteroskedastisitas, jika tidak ada indikasi heteroskedastisitas maka metode *Box-jenkins* sudah cukup untuk melakukan prediksi pada data tersebut jika tidak perlu dilanjutkan pada proses ARCH/GARCH.
6. Identifikasi Model ARCH-GARCH
Identifikasi model berfungsi dalam menentukan beberapa kemungkinan model yang akan digunakan.
7. Estimasi Parameter Model ARCH-GARCH
Estimasi dilakukan untuk mencari nilai koefisien dalam model.
8. Verifikasi Model
Uji independensi residual dan uji kenormalan residual dilakukan untuk melihat apakah model tersebut baik digunakan atau tidak.
9. Prediksi ARCH/GARCH
Setelah memperoleh model terbaik, maka selanjutnya adalah melakukan prediksi untuk memprediksi perubahan harga saham.

3. Hasil dan Pembahasan

3.1. Uji Kestasioneritasan Data

H_0 : Data tidak stasioner dalam rata-rata

H_1 : Data stasioner dalam rata-rata

$\alpha = 0.05$

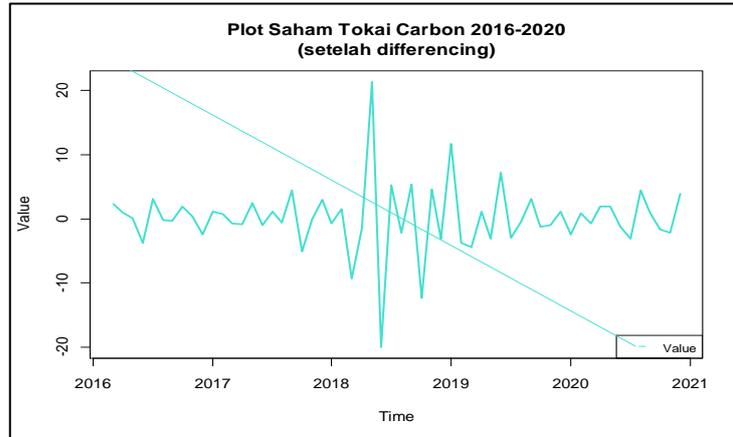
Tabel 2. Output Uji Augmented Dickey-Fuller

Augmented Dickey-Fuller Test		P-value
Dickey-Fuller	-7.0291	0.01

Berdasarkan Tabel 2 diatas, untuk data yang sudah dilakukan *differencing* sebanyak dua kali, didapatkan p-value bernilai 0.01. Karena $p\text{-value} = 0.01 < \alpha = 0.05$ maka H_0 ditolak. Artinya, dengan taraf signifikan 5% dapat disimpulkan bahwa setelah dilakukan dua kali differencing, data stasioner dalam rata-rata.

3.2. Identifikasi Model

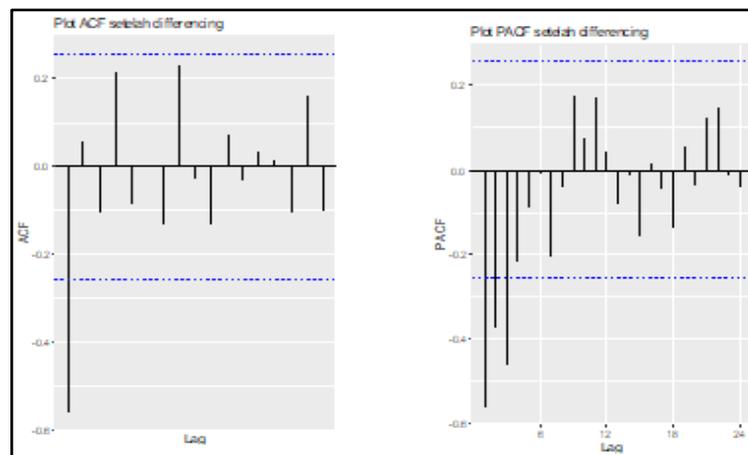
a. Plot Time Series



Gambar 1. Plot data historis saham Tokai Carbon setelah *differencing*

Setelah dilakukan pengujian dengan menggunakan Box-Cox, diketahui bahwa data historis saham Tokai Carbon 2016-2020 tidak stasioner dalam varians karena memiliki nilai λ sebesar 0.55. Oleh karena itu transformasi perlu dilakukan menggunakan perumusan y^λ .

b. Plot ACF dan PACF



Gambar 2. Plot ACF dan PACF setelah *differencing*

Data yang sudah stasioner dapat dilihat plot ACF dan PACF nya. Berdasarkan gambar 2, diperoleh bahwa pada ACF terdapat *cut off after lag-1*, serta pada PACF terdapat *cut off after lag-3*.

3.3. Estimasi Parameter Model dan Pemilihan Model Terbaik

Berdasarkan plot ACF diperoleh bahwa data *cut off after lag-1*, maka dugaan orde MA, $q = 1$, sedangkan dari plot PACF diperoleh bahwa data *cut off after lag-3*, maka dugaan orde AR, $p = 3$. Sehingga model ARIMA yang bisa terbentuk adalah ARIMA (0, 2, 1), ARIMA (1, 2, 0), ARIMA (2, 2, 0), ARIMA (3, 2, 0), ARIMA (1,2,1), ARIMA (2, 2, 1), dan

ARIMA (3, 2, 1). Untuk menentukan model terbaik, dilakukan pemilihan berdasarkan AIC dari setiap model. Model dengan AIC paling kecil merupakan model yang paling baik. Berdasarkan hasil perhitungan menggunakan software R, diperoleh nilai AIC terkecil pada model ARIMA (3, 2, 1) yakni sebesar 319.0283 yang dapat dilihat pada Tabel 3.

Tabel 3. Estimasi Parameter Model ARIMA (3,2,1)

Parameter	Koefisien	P-value	Signifikansi Parameter
ar1	-0.54896	0.004463	Signifikan
ar2	-0.42194	0.025662	Signifikan
ar3	-0.30281	0.048067	Signifikan
ma1	-0.55754	0.002625	Signifikan

$$Y_t = \Phi_1(Y_{t-1} - Y_{t-2}) + \dots + \Phi_4(Y_{t-4})$$

$$Y_t = \mu + (1 - 0.54896)Y_{t-1} + (-0.54896 + 0.42194)Y_{t-2} + (-0.42194 + 0.30281)Y_{t-3} + 0.55754e_{t-1}$$

$$Y_t = \mu + 0.45104Y_{t-1} - 0.12702Y_{t-2} - 0.11913Y_{t-3} - 0.30281Y_{t-4} + 0.55754e_{t-1}$$

3.4. Diagnostik Model

Model yang akan digunakan untuk prediksi terlebih dahulu harus memenuhi beberapa asumsi yakni stasioneritas data dan White Noise residual (berdistribusi normal, non-autokorelasi, homogenitas).

a. Uji Normalitas Residual

H_0 : $F(\alpha_t) = F_0(\alpha_t)$ (residual mengikuti distribusi normal)

H_1 : $F(\alpha_t) \neq F_0(\alpha_t)$ (residual tidak mengikuti distribusi normal)

$\alpha = 0.05$

Tabel 4. Output Uji Normalitas Residual

Kolmogorov-Smirnov Test	P-value
D	0.16667

Berdasarkan Tabel 4 diatas, diperoleh nilai p-value sebesar 0.3777. Karena nilai p-value (0.3777) > α (0.05), maka H_0 diterima. Artinya, dengan taraf signifikan 5% dapat disimpulkan bahwa residual mengikuti distribusi normal. Sehingga, asumsi normalitas terpenuhi.

b. Uji White Noise Autokorelasi

H_0 : $\rho_1 = \rho_2 = \dots = \rho_k = 0$ (artinya residual tidak berautokorelasi / memenuhi asumsi white Noise)

H_1 : minimal ada satu $\rho_k \neq 0$ (artinya residual berautokorelasi / tidak memenuhi asumsi white Noise)

$\alpha = 0.05$

Tabel 5. Output White Noise Autokorelasi

Box-Ljung Test	P-value
Chi-Square	0.0072497

Berdasarkan Tabel 5 diatas, diperoleh p-value sebesar 0.9321. Karena nilai p-value = 0.9321 > $\alpha = 0.05$, maka H_0 diterima. Artinya, dengan taraf signifikan 5% dapat

disimpulkan bahwa residual tidak berautokorelasi. Sehingga, asumsi non-autokorelasi terpenuhi.

c. Uji White Noise Heteroskedastisitas

H_0 : $\rho(1) = \dots = \rho(k) = 0$ (tidak terdapat efek heteroskedastisitas)

H_1 : paling tidak terdapat satu $\rho(k) \neq 0$, $k \in 1, 2, \dots, m$ (terdapat efek heteroskedastisitas)

$\alpha = 0.05$

Tabel 6. Output Uji White Noise Heteroskedastisitas

Box-Ljung Test		P-value
Chi-Square	17.782	2.477×10^{-5}

Melalui tabel 6 diperoleh p -value sebesar 2.477×10^{-5} . Karena p -value $2.477 \times 10^{-5} < \alpha = 0.05$ maka H_0 ditolak. Artinya, dengan taraf signifikan 5% dapat disimpulkan bahwa residual bersifat heterogen. Sehingga, asumsi homogenitas tidak terpenuhi. Karena model ARIMA (3,2,1) tidak memenuhi asumsi homogenitas, maka perlu diidentifikasi adanya efek ARCH pada model.

3.5. Uji ARCH-LM

H_0 : Efek ARCH pada model tidak terdeteksi

H_1 : Efek ARCH pada model terdeteksi

$\alpha = 0.05$

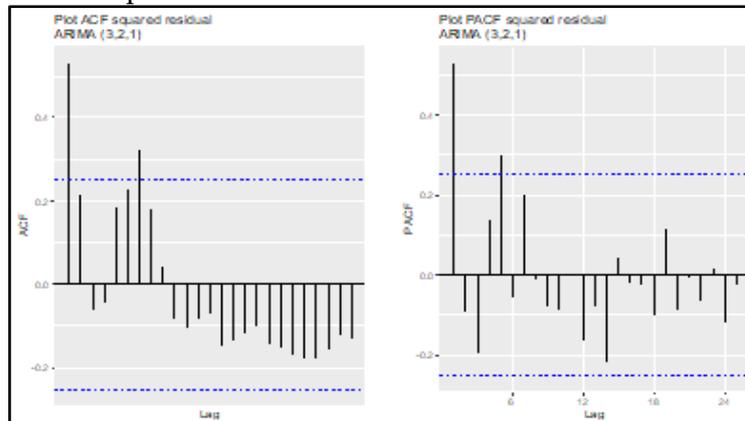
Tabel 7. Output Uji ARCH-LM

ARCH-LM Test		P-value
Chi-Square	41.315	1.296×10^{-10}
F	66.39	3.905×10^{-11}

Berdasarkan output diatas, untuk statistik uji Chi-Squared diperoleh nilai p-value sebesar 1.296×10^{-10} . Statistik uji F diperoleh nilai p-value sebesar 3.905×10^{-11} . Karena nilai dari kedua p-value $< \alpha = 0.05$ maka H_0 ditolak. Artinya, dengan taraf signifikansi sebesar 5% dapat disimpulkan bahwa terdapat efek ARCH pada model ARIMA (3,2,1).

3.6. Identifikasi Model ARCH/GARCH

a. Plot ACF dan PACF Squared Residual



Gambar 3. Plot ACF dan PACF Squared Residual ARIMA (3,2,1)

Berdasarkan Gambar 3, hasil plot ACF dan PACF dapat diketahui bahwa kemungkinan model yang dapat terbentuk adalah GARCH (0,1), GARCH (1,0), dan GARCH (1,1). Pemilihan model terbaik didasarkan pada AIC dari ketiga model tersebut. Melalui hasil perhitungan menggunakan software R, diperoleh nilai AIC terkecil adalah pada model GARCH (0,1) yakni sebesar 296.4776, maka model terbaik yang dapat dipilih adalah model GARCH (0,1).

$$\sigma_t^2 = 5.5090 + 0.4601\epsilon_{t-1}^2$$

3.7. Estimasi Parameter Model ARCH/GARCH

H_0 : $\theta = 0$ (artinya parameter tidak signifikan)

H_1 : $\theta \neq 0$ (artinya parameter signifikan)

$\alpha = 0.05$

Tabel 8. Estimasi dan Uji Signifikansi Parameter

Parameter	Koefisien	P-value	Signifikansi
a0	5.5090	2.74×10^{-13}	Signifikan
a1	0.4601	0.065	Tidak Signifikan

3.8. Verifikasi Model

a. Uji Autokorelasi

H_0 : $\rho_1 = \rho_2 = \dots = \rho_k = 0$ (artinya residual tidak berautokorelasi / memenuhi asumsi white Noise)

H_1 : minimal ada satu $\rho_k \neq 0$ (artinya residual berautokorelasi / tidak memenuhi asumsi white Noise)

$\alpha = 0.05$

Tabel 9. Output Uji Autokorelasi

Box-Ljung Test		P-value
Chi-Square	0.00037651	0.9845

Berdasarkan Tabel 9 diperoleh p-value bernilai 0.9845. Karena p-value = 0.9845 > $\alpha = 0.05$, maka H_0 diterima. Artinya, dengan taraf signifikansi 5% dapat disimpulkan bahwa residual tidak berautokorelasi.

b. Rumusan Model

GARCH (0,1) yang diperoleh adalah :

$$h_t = 5.5090 + 0.4601\epsilon_{t-1}^2$$

Model ARIMA (3,2,1) yang telah diperoleh sebelumnya adalah :

$$Y_t = 0.45104Y_{t-1} - 0.12702Y_{t-2} - 0.11913Y_{t-3} - 0.30281Y_{t-4} + 0.55754e_{t-1}$$

Model ARIMA (3,2,1) + GARCH (0,1) adalah :

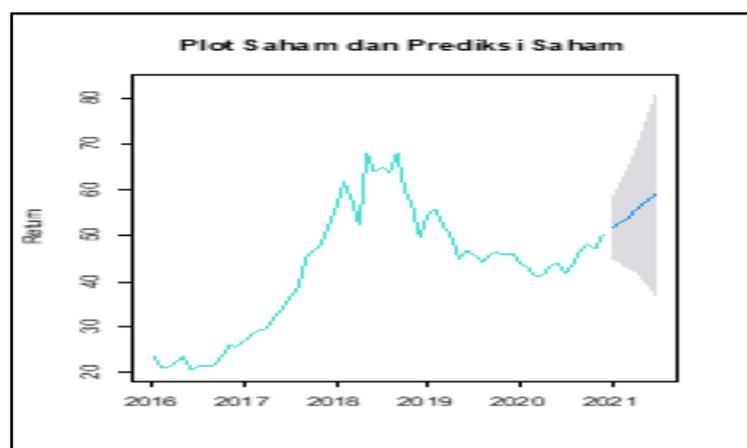
$$Y_t = 5.5090 + 0.45104Y_{t-1} - 0.12702Y_{t-2} - 0.11913Y_{t-3} - 0.30281Y_{t-4} + 0.55754e_{t-1}$$

3.9. Prediksi

Setelah mendapatkan model terbaik yaitu ARIMA(3,2,1)-GARCH(0,1) maka dapat dilakukan peramalan data historis saham Tokai Carbon untuk 7 bulan kedepan dapat dilihat pada Tabel 10. Berdasarkan gambar 4 melalui hasil penelitian ini menunjukkan bahwa saham Tokai Carbon akan mengalami kenaikan dalam beberapa periode ke depan.

Tabel 10. Prediksi Data Historis Saham Tokai Carbon 7 Periode ke Depan

Periode	Forecast	Low	High
Januari 2021	51.71934	45.01455	58.42413
Februari 2021	52.98341	43.99213	61.97469
Maret 2021	53.84850	42.74184	64.95515
April 2021	55.50464	42.12118	68.88809
Mei 2021	56.88270	40.23155	73.53386
Juni 2021	58.20046	38.25816	78.14277
Juli 2021	59.42912	36.13475	82.72349



Gambar 4. Plot data prediksi saham dan conditional varians

4. Kesimpulan

Berdasarkan hasil analisis yang telah dilakukan, maka dapat disimpulkan bahwa GARCH(0, 1) merupakan model yang terbaik untuk memprediksi data historis saham Tokai Carbon berdasarkan prosedur pengujian yang dilakukan. Dari hasil perhitungan dan berdasarkan nilai AIC terkecil yang diperoleh sebesar 296.4776, serta diperoleh nilai MAPE untuk model sebesar 4.949972%. Berdasarkan nilai AIC dan nilai MAPE, dapat disimpulkan bahwa model GARCH (0,1) sudah cukup baik untuk memprediksi harga saham perusahaan Tokai Carbon.

Daftar Pustaka

- [1] J. Salim, "Cara Gampang Bermain Saham," W. Oktavia, Ed. VisiMedia, 2010, pp. 3–4.
- [2] W. Enders, *Applied Econometric Time Series*. USA: John Wiley & Son, Inc., 1995.
- [3] B. L. Marvillia, "Saham Pt . Telkom Dengan Metode," *J. Ilm. Mat.*, vol. 2, 2013.
- [4] C. W. Elvitra, B. Warsito, and A. Hoyyi, "Metode Prediksi Dengan Menggunakan Model Volatilitas Asymmetric Power Arch (Aparch)," *J. Gaussian*, vol. 2, no. 4, pp. 289–300, 2013.
- [5] Ariefianto and M. Doddy, *Ekonometrika Esensi dan Aplikasi dengan Menggunakan EViews*. Jakarta: Erlangga, 2012.
- [6] A. P. Raneo and F. Muthia, "Penerapan Model GARCH Dalam Prediksi Volatilitas di Bursa Efek Indonesia," *J. Manaj. Dan Bisnis Sriwij.*, vol. 16, no. 3, pp. 194–202,

- 2019.
- [7] K. Nurfadilah, F. R. C, and I. Kasse, "Prediksi Tingkat Suku Bunga Pasar Uang Antar Bank (Puab) Dengan Vector Autoregressive Exogenous (Varx)," *J. MSA (Mat. dan Stat. serta Apl.)*, vol. 6, no. 1, p. 51, 2018.
 - [8] S. Makridakis, S. C.Wheelright, and V. E.McGee, *Metode dan Aplikasi Prediksi*. Jakarta Barat: Binarupa Aksara, 1999.
 - [9] Desvina and A. Pani, "Analisis Time Series Particulate Matter (PM10)," *Lemb. Penelit. dan Pengabd. Kpd. Masy. UIN SUSKA*, 2014.
 - [10] Cryer, J. D., and K.-S. Chan, *Time Series Analysis with Application in R*, Second. Iowa City: Springer, 2008.
 - [11] A. pani desvina dan Khairunisa, "Penerapan Metode Arch / Garch Dalam Meramalkan Transaksi Nilai Tukar (Kurs) Jual Mata Uang Indonesia (IDR) Terhadap Mata Uang Eropa (GBP)," *J. Sains Mat. dan Stat.*, vol. 4, no. 2, pp. 114–123, 2018.
 - [12] F. Pakaja and A. Naba, "Prediksi Penjualan Mobil Menggunakan Jaringan Syaraf Tiruan dan Certainty Factor," *Neural Networks*, vol. 6, no. 1, pp. 23–28, 2015.
 - [13] P. C. Chang, Y. W. Wang, and C. H. Liu, "The development of a weighted evolving fuzzy neural network for PCB sales forecasting," *Expert Syst. Appl.*, vol. 32, no. 1, pp. 86–96, 2007.