

ANALISIS VOLATILITAS BITCOIN MENGGUNAKAN MODEL ARCH DAN GARCH

Dheanisa Widyanti^{1*}, Sudarno², Tatik Widiharah³

^{1,2,3}Departemen Statistika, Fakultas Sains dan Matematika, Universitas Diponegoro

*e-mail: dheanisawidyanti@gmail.com

DOI: 10.14710/J.GAUSS.12.2.254-265

Article Info:

Received: 2022-11-11

Accepted: 2023-03-21

Available Online: 2023-07-28

Keywords:

Bitcoin; Return;

Heteroscedasticity; ARCH;

GARCH; ARIMA

Abstract: The popularity of Bitcoin increased significantly in 2021. Bitcoin is considered to deliver high returns in a relatively short period, indicating that bitcoin has high volatility. Data with high volatility usually violates the *Autoregressive Integrated Moving Average* (ARIMA) homoscedasticity assumption. The *Autoregressive Conditional Heteroscedasticity* (ARCH) and *General Autoregressive Conditional Heteroscedasticity* (GARCH) model is often used to overcome the problem of heteroscedasticity in the ARIMA model. The ARCH and GARCH models can be used to model the volatility of data. This Research uses ARCH and GARCH models to overcome the heteroscedasticity problem caused by the high volatility of Bitcoin data for the period 30th June 2018 to 30th June 2022. The results of this study suggest that there might be a heteroscedasticity problem in Bitcoin data. The best model for Bitcoin data is ARIMA(1,0,[4])-GARCH(1,1) with an AIC value of -1,4263 at a 95% confidence level.

1. PENDAHULUAN

Revolusi industri 4.0 menjadikan kehidupan manusia tidak lagi bisa dipisahkan dari teknologi. Pesatnya perkembangan teknologi, khususnya pada sektor ekonomi. Hal ini dapat dilihat dari munculnya uang elektronik di tengah masyarakat yang juga dapat digunakan sebagai alat pembayaran. Uang elektronik yang digunakan di berbagai belahan dunia sangat beragam, salah satunya adalah *cryptocurrency* atau mata uang kripto. Sebagian orang menggunakan *cryptocurrency* sebagai aset investasi karena dianggap dapat memberikan *return* yang tinggi dalam waktu yang relatif cepat. Harga yang berubah secara dramatis dalam periode waktu yang berdekatan menandakan adanya volatilitas yang tinggi (Hayes, 2021). Data dengan volatilitas tinggi menunjukkan adanya masalah heteroskedastisitas (Saluza, 2017). Masalah heteroskedastisitas merupakan suatu pelanggaran dari model ARIMA (*Autoregressive Integrated Moving Average*). Analisis peramalan dengan model yang dapat menangani masalah heteroskedastisitas, seperti model *Autoregressive Conditional Heteroscedasticity* (ARCH) dan *General Autoregressive Conditional Heteroscedasticity* (GARCH), perlu dilakukan sebelum berinvestasi pada *cryptocurrency*. Model ARCH dan GARCH merupakan model volatilitas untuk data runtun waktu. Model ARCH mengasumsikan bahwa varian residual tidak konstan. Model GARCH merupakan pengembangan dari model ARCH. Varian bersyarat pada model GARCH tidak hanya berhubungan dengan residual pada data sebelumnya, tetapi juga berhubungan dengan variansi residual sebelumnya.

Penelitian mengenai analisis volatilitas Bitcoin dan *cryptocurrency* lain telah dilakukan oleh beberapa peneliti sebelumnya. Katsiampa (2017) meneliti data *return* harga Bitcoin periode 18 Juli 2010 sampai 1 Oktober 2016 menggunakan beberapa model GARCH dengan asumsi residual mengikuti distribusi normal dan mendapatkan kesimpulan bahwa model AR(1)-CGARCH(1,1) merupakan model terbaik untuk data yang digunakan. Ngunyi *et al.* (2019) menganalisis peramalan *Value at Risk* (VaR) menggunakan model GARCH untuk data delapan *cryptocurrency* populer periode 7 Agustus 2015 sampai 1 Agustus 2018

dan mendapat kesimpulan bahwa distribusi t , GED, dan hiperbolik dengan kemiringan memiliki kemampuan prediksi yang lebih baik. Naimy *et al.* (2021) mengevaluasi dan menentukan model volatilitas *cryptocurrency* menggunakan berbagai model GARCH terhadap mata uang *fiat* pada periode 13 Oktober 2015 sampai 18 November 2019 dan menghasilkan kesimpulan bahwa *cryptocurrency* yang paling stabil kendatipun memiliki volatilitas sepuluh kali lebih tinggi dibanding mata uang *fiat* yang paling tidak stabil, Almansour *et al.* (2021) menggunakan model ARCH dan GARCH pada data sembilan mata uang kripto tahun 2010 sampai 2020 dan menemukan adanya efek asimetri pada data yang digunakan, Khairunnisa *et al.* (2022) melakukan analisis terhadap data berbagai jenis *cryptocurrency* periode 11 Maret 2020 sampai 11 Juni 2020 dan menemukan mata uang kripto Bitcoin menghasilkan *return* negatif selama pandemi COVID-19.

Penelitian ini merupakan pengembangan dari penelitian-penelitian terdahulu dengan menggunakan data terbaru, yaitu data *return* penutupan harian Bitcoin periode 30 Juni 2018 sampai 30 Juni 2022 sebanyak 1462 data dimana pada periode tersebut terdapat data dengan volatilitas tinggi yang ditandai dengan kenaikan harga Bitcoin tertinggi dibandingkan dengan periode-periode sebelumnya. Metode ARCH dan GARCH digunakan karena kedua metode tersebut merupakan metode yang paling sesuai untuk data yang digunakan pada taraf signifikansi 5%. Tujuan dari penelitian ini adalah untuk melihat ada tidaknya masalah heteroskedastisitas, mengetahui model volatilitas, dan model terbaik untuk data Bitcoin pada periode yang telah ditentukan.

2. TINJAUAN PUSTAKA

Bitcoin merupakan mata uang digital yang diciptakan pada tahun 2008 oleh Satoshi Nakamoto. Bitcoin menggunakan pengembangan teknologi *blockchain* dan memiliki sifat yang terdesentralisasi. Sistem ini membatasi jumlah *votes* per entitas dalam skema PoW (*Proof of Work*). Bitcoin tidak hanya digunakan sebagai mata uang digital, namun juga digunakan beberapa orang sebagai suatu aset investasi karena dianggap dapat menghasilkan *return* yang tinggi dalam jangka waktu yang relatif singkat.

Return yang dipakai pada penelitian ini dihitung menggunakan metode *Continuously compounded return* dengan rumus berikut.

$$r_t = \ln \frac{P_t}{P_{t-1}} \quad (1)$$

dengan:

r_t = nilai *return* pada waktu ke- t

P_t = harga penutupan aset pada periode ke- t

P_{t-1} = harga penutupan aset pada periode ke- $(t-1)$

Continuously compounded return cocok digunakan untuk data Bitcoin karena metode ini menganggap tidak ada batasan seberapa sering bunga dapat bertambah. *Return* yang tinggi juga dapat diasosiasikan dengan volatilitas yang tinggi (Daly, 2008).

Salah satu syarat dari analisis runtun waktu ARIMA adalah data stasioner. Stasioner berarti bahwa tidak terjadi peningkatan dan pengurangan data (Makridakis *et al.*, 1998). Suatu data runtun waktu dikatakan stasioner apabila data stasioner dalam *mean* dan stasioner dalam varian. Uji stasioneritas dalam *mean* didasarkan dari persamaan runtun waktu sederhana AR(1) sebagai berikut.

$$r_t = \phi_1 r_{t-1} + a_t \quad (2)$$

dengan:

r_t = nilai *return* pada waktu ke- t

r_{t-1} = nilai *return* pada waktu $t-1$

ϕ_1 = parameter *autoregressive* pada lag ke-1

a_t = nilai residual pada saat ke- t

Bersadarkan Persamaan 2, uji stasioneritas dalam *mean* dengan uji *augmented dickey fuller* dapat dilakukan dengan rumus berikut.

$$ADF_{hitung} = \frac{\hat{\theta}_1 - 1}{se(\hat{\theta}_1)} \quad (3)$$

dengan $\hat{\theta}_1 = \frac{\sum_{t=1}^n r_{t-1} r_t}{\sum_{t=1}^n r_{t-1}^2}$ dan n merupakan ukuran sampel (Tsay, 2002). Hipotesis nol dari uji *augmented dickey fuller* ditolak apabila nilai ADF hitung $<$ ADF tabel atau nilai *p-value* $<$ α yang berarti data stasioner dalam *mean*. Uji stasioneritas dalam varian dilakukan menggunakan uji transformasi *Box-Cox* sebagai berikut.

$$t(r_t) = \begin{cases} \frac{r_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln r_t, & \lambda = 0 \end{cases} \quad (4)$$

dengan λ merupakan parameter lambda (Tsay, 2002). Hipotesis nol dari uji transformasi *Box-Cox* ditolak apabila memiliki nilai $\lambda = 1$ nilai *p-value* $<$ α yang dapat diartikan bahwa data stasioner dalam varian.

Model ARIMA atau model *Autoregressive Integrated Moving Average* merupakan model gabungan dari model *Autoregressive* (AR) dan *Moving Average* (MA). Model ARIMA dapat ditulis sebagai berikut (Hyndman dan Athanasopoulos, 2018).

$$\phi(B)(1 - B)^d r_t = \phi_0 + \theta(B)a_t \quad (5)$$

dengan:

r_t = nilai *return* pada waktu ke- t , $t = 1, 2, \dots, n$

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

ϕ_p = parameter *Autoregressive* ke- p , p = order AR

$\phi_0 = \mu(1 - \phi_1 - \phi_2 - \dots - \phi_p)$

μ = konstanta *mean* (*intercept*) dari r_t

$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$

θ_q = parameter *Moving Average* ke- q , q = order MA

Identifikasi model ARIMA dilakukan untuk mencari nilai ordo p dan q dari model ARIMA. Nilai ordo dipilih berdasarkan lag signifikan pada plot *Autocorrelation Function* (ACF) untuk nilai orde p dan plot *Partial Autocorrelation Function* (PACF) untuk nilai orde q . Lag dikatakan signifikan apabila nilai lag berada diluar rentang nilai autokorelasi.

Model ARIMA yang telah teridentifikasi kemudian dilakukan estimasi parameter. Estimasi parameter model AR(p) diperoleh dengan menggunakan metode Yule-Walker, sehingga estimasi parameter ARIMA dapat ditulis sebagai berikut (Wei, 2006).

$$\begin{pmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \\ \vdots \\ \hat{\phi}_p \end{pmatrix} = \begin{pmatrix} 1 & \hat{\rho}_1 & \dots & \hat{\rho}_{k-1} \\ \hat{\rho}_1 & 1 & \dots & \hat{\rho}_{k-2} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\rho}_{k-1} & \hat{\rho}_{k-2} & \dots & 1 \end{pmatrix}^{-1} \begin{pmatrix} \hat{\rho}_1 \\ \hat{\rho}_2 \\ \vdots \\ \hat{\rho}_k \end{pmatrix} \quad (6)$$

dengan $\hat{\rho}_k = \frac{\sum_{t=k+1}^n (r_t - \bar{r})(r_{t-k} - \bar{r})}{\sum_{t=k+1}^n (r_t - \bar{r})^2}$ merupakan fungsi autokorelasi pada lag ke- k , $\bar{r} = \frac{1}{n} \sum_{t=1}^n r_t$, p merupakan order AR.. Parameter model MA(q) dapat diestimasi sebagai berikut.

$$(\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_q)_{s+1} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_q)_s - \mathbf{H}(\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_q)^{-1} \mathbf{g}_t \quad (7)$$

dengan:

$$\mathbf{g}_t = \left[\frac{\partial L}{\partial \theta_1}, \frac{\partial L}{\partial \theta_2}, \dots, \frac{\partial L}{\partial \theta_q} \right]^T$$

$$H(\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_q) = \begin{bmatrix} \frac{\partial^2 L}{\partial \theta_1 \partial \theta_1} & \dots & \frac{\partial^2 L}{\partial \theta_1 \partial \theta_q} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 L}{\partial \theta_q \partial \theta_1} & \dots & \frac{\partial^2 L}{\partial \theta_q \partial \theta_q} \end{bmatrix}$$

Parameter yang telah diestimasi dikenakan uji signifikansi parameter untuk menguji parameter dari masing-masing model apakah parameter signifikan terhadap model.

Model runtun waktu ARIMA memiliki tiga asumsi yang harus dipenuhi, yaitu asumsi normalitas residual, asumsi independensi residual, dan asumsi homoskedastisitas.

1. Asumsi Normalitas Residual ARIMA

Asumsi ini menguji apakah residual dari model yang didapat berdistribusi normal. Normalitas residual dapat diuji menggunakan uji *Jarque-Berra*. Performa uji *Jarque-Berra* dinilai dapat melebihi performa uji *Kolmogorov-Smirnov* (Tomšik, 2019). Nilai *Jarque-Berra* dapat dihitung dengan rumus sebagai berikut.

$$JB = \frac{n}{6} \left(S^2 + \frac{(K-3)^2}{4} \right) \quad (8)$$

dengan $S^2 = \frac{\sum_{t=1}^n (a_t - \bar{a})^3}{n \left(\frac{1}{n} \sum_{t=1}^n (a_t - \bar{a})^2 \right)^{3/2}}$ merupakan nilai *skewness*, $K = \left(\frac{\sum_{t=1}^n (a_t - \bar{a})^4}{n \left(\frac{1}{n} \sum_{t=1}^n (a_t - \bar{a})^2 \right)^2} \right)$

merupakan nilai kurtosis, $\bar{a} = \frac{\sum_{t=1}^m a_t}{n}$, a_t adalah residual dari ARIMA, JB merupakan nilai *Jarque-Bera*, dan n merupakan banyaknya data (Cryer dan Chan, 2008). Hipotesis nol dari uji *Jarque-Berra* ditolak apabila jika nilai $JB > \chi_{(2)}^2$ atau nilai $p\text{-value} < \alpha$ yang berarti bahwa residual dikatakan tidak berdistribusi normal.

2. Asumsi Independensi Residual ARIMA

Residual model ARIMA diasumsikan tidak memiliki korelasi antar lag residual (independen). Independensi residual dapat diuji dengan menggunakan uji *Ljung-Box* dengan rumus sebagai berikut

$$LB = n(n+2) \sum_{k=1}^m \left(\frac{\eta_k^2}{n-k} \right) \quad (9)$$

dengan $\eta_k = \frac{\sum_{t=k+1}^n (a_t - \bar{a})(a_{t-k} - \bar{a})}{\sum_{t=1}^n (a_t - \bar{a})^2}$, $\bar{a} = \frac{\sum_{t=1}^m a_t}{n}$, η_k adalah koefisien autokorelasi dari residual, a_t adalah residual dari ARIMA, $m \approx \ln(n)$ adalah lag maksimum, dan n adalah ukuran sampel (Cryer dan Chan, 2008). Hipotesis nol dari uji *Ljung-Box* ditolak apabila nilai $LB > \chi_{(m)}^2$ atau nilai $p\text{-value} < \alpha$ yang berarti terdapat korelasi antar residual.

3. Asumsi Homoskedastisitas Residual ARIMA

Residual ARIMA diasumsikan tidak memiliki efek heteroskedastisitas. Efek heteroskedastisitas dapat diuji menggunakan uji *Lagrange Multiplier*. Uji ini juga dapat digunakan untuk melihat ada tidaknya efek ARCH/GARCH pada residual ARIMA. Uji *Lagrange Multiplier* dilakukan dengan rumus sebagai berikut,

$$LM = \frac{(SSR_0 - SSR_1)/u}{SSR_1/(n-2u-1)} \quad (10)$$

dengan $SSR_0 = \sum_{t=u+1}^n (a_t^2 - \bar{\omega})^2$, $\bar{\omega} = \frac{\sum_{t=1}^n a_t^2}{n}$, $SSR_1 = \sum_{t=u+1}^n e_t^2$, e_t^2 merupakan kuadrat residual terkecil dari persamaan, dan u merupakan bilangan bulat positif yang ditentukan (Tsay, 2002). Hipotesis nol dari uji *Ljung-Box* ditolak apabila nilai $LM > \chi_p^2(\alpha)$ atau $p\text{-value} < \alpha$ yang dapat diartikan bahwa residual memiliki efek heteroskedastisitas dan efek ARCH.

Data yang memiliki residual dengan efek heteroskedastisitas tidak cocok dilakukan permodelan ARIMA karena terdapat asumsi yang melanggar. Engle mengembangkan suatu metode bernama *Autoregressive Conditional Heteroscedasticity* (ARCH) untuk mempermudah penyelesaian permasalahan tersebut. Model ARCH(g) menurut Engle (1982) dapat dinyatakan sebagai berikut.

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \alpha_p a_{t-g}^2, \quad (11)$$

dengan a_t merupakan residual yang dari model ARIMA α_0 merupakan konstan, α_g merupakan parameter residual ARIMA pada lag ke- g , g merupakan orde ARCH, $\alpha_0 > 0$ dan $\alpha_g \geq 0$ untuk $g > 0$.

Bollerslev menciptakan pengembangan model ARCH yang diberi nama *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Model GARCH(p,q) menurut Bollerslev (1986) sebagai berikut:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^g \alpha_i a_{t-i}^2 + \sum_{j=1}^h \beta_j \sigma_{t-j}^2 \quad (12)$$

dengan a_t merupakan residual yang dari model ARIMA, σ_t^2 merupakan variansi residual pada waktu ke- t , α_0 merupakan konstan, α_i merupakan parameter residual ARIMA, β_j merupakan parameter variansi residual ARIMA, g dan h merupakan orde pada model GARCH, $\alpha_0 > 0$, $\alpha_i \geq 0$, $\beta_j \geq 0$ untuk $\sum_{i=1}^{\max(g,h)} (\alpha_i + \beta_i) < 1$.

Model ARCH dan GARCH yang telah teridentifikasi kemudian dilakukan estimasi parameter. Estimasi parameter untuk model ARCH(g) sebagai berikut.

$$(\hat{\alpha}_0, \hat{\alpha}_1, \dots, \hat{\alpha}_g)_{s+1} = (\hat{\alpha}_0, \hat{\alpha}_1, \dots, \hat{\alpha}_g)_s - \mathbf{H}(\alpha_0, \alpha_1, \dots, \alpha_g)^{-1} \mathbf{gt} \quad (13)$$

dan estimasi parameter untuk model GARCH(g,h) sebagai berikut.

$$(\hat{\alpha}_0, \hat{\alpha}_1, \dots, \hat{\alpha}_g, \hat{\beta}_1, \dots, \hat{\beta}_h)_{s+1} = (\hat{\alpha}_0, \hat{\alpha}_1, \dots, \hat{\alpha}_g, \hat{\beta}_1, \dots, \hat{\beta}_h)_s - \mathbf{H}(\alpha_0, \alpha_1, \dots, \alpha_g, \beta_1, \dots, \beta_h)^{-1} \mathbf{gt} \quad (14)$$

dengan:

$(\hat{\alpha}_0, \hat{\alpha}_1, \dots, \hat{\alpha}_g, \hat{\beta}_1, \dots, \hat{\beta}_h)_{s+1}$ = estimasi parameter $\alpha_0, \alpha_1, \dots, \alpha_p$ dan parameter β_1, \dots, β_q pada iterasi ke-($s+1$).

$(\hat{\alpha}_0, \hat{\alpha}_1, \dots, \hat{\alpha}_p, \hat{\beta}_1, \dots, \hat{\beta}_q)_s$ = estimasi parameter $\alpha_0, \alpha_1, \dots, \alpha_p$ dan parameter β_1, \dots, β_q pada iterasi ke- s .

$(\hat{\alpha}_0, \hat{\alpha}_1, \dots, \hat{\alpha}_g)_{s+1}$ = estimasi parameter $\alpha_0, \alpha_1, \dots, \alpha_g$ pada iterasi ke-($s+1$).

$(\hat{\alpha}_0, \alpha_1, \dots, \hat{\alpha}_g)_s$ = estimasi parameter $\alpha_0, \alpha_1, \dots, \alpha_g$ pada iterasi ke- s .

$\mathbf{H}(\alpha_0, \alpha_1, \dots, \alpha_g)$ = matriks hessian untuk parameter $\alpha_0, \alpha_1, \dots, \alpha_g$

$\mathbf{H}(\alpha_0, \alpha_1, \dots, \alpha_p, \beta_1, \dots, \beta_q)$ = matriks hessian untuk parameter $\alpha_0, \alpha_1, \dots, \alpha_p$ dan parameter β_1, \dots, β_q

\mathbf{gt} = vektor gradient yang merupakan turunan likelihood model yang diturunkan terhadap setiap parameter model.

Engle dan Ng memperkenalkan uji *Sign and Size Bias* yang dapat digunakan untuk menguji adanya efek asimetris pada data. Uji *Sign and Size Bias* juga disebut dengan uji tanda dan ukuran bias. Uji ini terdiri dari empat uji, yaitu uji tanda bias, uji ukuran bias positif, uji ukuran bias negatif, dan uji efek gabungan (*joint effect*). Uji tanda bias, uji ukuran bias positif dan uji ukuran bias negatif diuji berdasarkan uji t dengan hipotesis nol ditolak apabila $|t_{hitung}| > t_{(\alpha/2; n-1)}$ atau $p\text{-value} < \alpha$ yang berarti residual tidak bersifat simetris. *Joint effect* diuji dengan uji *Lagrange Multiplier* dengan hipotesis nol residual bersifat simetris.

Peramalan dapat menghasilkan lebih dari satu model yang sesuai dengan data tersebut sehingga diperlukan kriteria pemilihan model untuk memilih model terbaik. Kriteria

pemilihan model biasanya dilihat berdasarkan rangkuman statistik residual dari *fitted model* atau berdasarkan *error* peramalan dari hasil analisis data (Wei, 2006). Terdapat berbagai metode kriteria pemilihan model yang dapat dipakai, adalah *Akaike's Information Criterion* (AIC) dengan rumus sebagai berikut.

$$AIC = n \log \left(\frac{SSR}{n} \right) + 2m \quad (13)$$

Model terbaik memiliki nilai AIC paling kecil (Wei, 2006).

3. METODE PENELITIAN

Data yang digunakan pada penelitian ini adalah data sekunder yang didapat dari situs Yahoo! Finance (www.finance.yahoo.com), yaitu data harga penutupan harian Bitcoin (dalam US Dollar) tanggal 30 Juni 2018 sampai tanggal 30 Juni 2022. Data tersebut digunakan untuk mencari data *return* yang akan dimodelkan dengan model ARCH (*Autoregressive Conditional Heteroscedasticity*), dan GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*). Tahapan analisis data pada penelitian ini dapat dituliskan sebagai berikut:

1. Menghitung *return* dari data harian harga penutupan harian Bitcoin.
2. Melakukan analisis statistik deskriptif berdasarkan data *return*.
3. Melakukan uji stasioneritas data *return* dalam varian dengan metode *Box-Cox*.
4. Melakukan uji stasioneritas data *return* dalam *mean* dengan uji *Augmented Dickey-Fuller*
5. Melakukan identifikasi model ARIMA dengan menggunakan plot dan tabel ACF dan PACF.
6. Melakukan estimasi parameter model ARIMA.
7. Melakukan uji signifikansi parameter model ARIMA.
8. Verifikasi model menggunakan uji normalitas residual dengan uji *Jarque-Bera* dan uji independensi residual dengan uji *Ljung-Box*, dan uji heteroskedastisitas dengan uji *Lagrange Multiplier*.
9. Pemilihan model ARIMA terbaik berdasarkan nilai AIC model.
10. Identifikasi model GARCH menggunakan plot dan tabel ACF dan PACF.
11. Melakukan estimasi parameter model ARCH/GARCH.
12. Melakukan uji signifikansi parameter ARCH/GARCH.
13. Melakukan uji *Sign and Size Bias* untuk mengetahui efek asimetris.
14. Memilih model terbaik diantara model akhir berdasarkan nilai AIC model.
15. Melakukan uji independensi residual pada model terbaik.
16. Intepretasi hasil dan penarikan kesimpulan.


4. HASIL DAN PEMBAHASAN

Data data harga penutupan harian Bitcoin tanggal 30 Juni 2018 sampai tanggal 30 dihitung untuk mendapatkan data *return*. Data *return* dilakukan uji statistic deskriptif dan mendapat hasil yang dapat dilihat pada Tabel 1.

Tabel 1. Statistik Deskriptif Data *Return* Bitcoin

Ukuran	<i>Return</i>
<i>Mean</i>	0,0008
Minimum	-0,4647
Maksimum	0,1718
Standar Deviasi	0,0385
<i>Skewness</i>	-1,2134
Kurtosis	16,5883


Berdasarkan Tabel 1, terlihat bahwa data *return* memiliki nilai *skewness* sebesar -1,2134 dan nilai kurtosis sebesar 16,5883. Hal tersebut menunjukkan bahwa data *return* Bitcoin tidak berdistribusi normal. Nilai kurtosis lebih dari 3 menandakan bahwa data memiliki kurva leptokurtik (Brooks, 2019). Data dengan kurva leptokurtik dapat menggunakan distribusi *student-t* dan GED sebagai distribusi alternatif ekor berat (Tsay, 2002). Plot dari data *return* Bitcoin dapat dilihat pada Gambar 1.



Gambar 1. Plot Data *Return* Bitcoin

Berdasarkan Gambar 1, terlihat bahwa data memiliki *mean* yang konstan sehingga dapat dikatakan data stasioner dalam mean. Data memiliki pola volatilitas besar yang diikuti oleh volatilitas kecil dan volatilitas kembali membesar. Hal tersebut menandakan bahwa data tidak stasioner dalam varian. Stasioneritas dapat dilihat lebih jelas melalui uji *Box-Cox* dan uji *Augmented Dickey Fuller*.

Uji stasioneritas dalam varian dilakukan menggunakan uji *Box-Cox* dengan melihat nilai λ . Berdasarkan uji *Box-Cox*, didapatkan nilai λ sebesar 3 yang menunjukkan bahwa H_0 gagal ditolak sehingga data *return* harga Bitcoin tidak stasioner dalam varian sehingga diperlukan transformasi menggunakan metode *Box-Cox*. Data yang telah ditransformasi diuji kembali dan didapatkan hasil nilai λ sebesar 1 yang mengartikan bahwa H_0 ditolak sehingga data *return* harga Bitcoin sudah stasioner dalam varian. Berdasarkan hasil pengujian stasioneritas dalam *mean* menggunakan uji *Augmented Dickey Fuller* (ADF) diperoleh nilai ADF hitung sebesar -17,9180, ADF tabel sebesar -2,863, dan nilai *p-value* sebesar 0,0000. Nilai $ADF_{hitung} < ADF_{tabel}$ dan nilai $p\text{-value} < 0,05$ menunjukkan bahwa H_0 ditolak sehingga dapat diartikan data *return* Bitcoin stasioner dalam *mean*.



Gambar 2. Plot ACF dan PACF Data Return Harga Penutupan Harian Bitcoin

Data yang telah stasioner dalam *mean* dan varian dilakukan proses identifikasi menggunakan plot *Autocorrelation Function* (ACF) dan plot *Partial Autocorrelation Function* (PACF) yang disajikan pada Gambar 2.

Berdasarkan Gambar 2, didapatkan lag signifikan pada plot ACF dan PACF untuk data *return* Bitcoin adalah lag 1 dan 4. Model yang terbentuk dari hasil identifikasi model adalah ARIMA(0,0,1), ARIMA(1,0,0), ARIMA(1,0,1), ARIMA(1,0,[4]), ARIMA(1,0,[1,4]), ARIMA(0,0,[4]), ARIMA([4],0,0), ARIMA([4],0,1),

ARIMA([4],0,[1,4]), ARIMA([4],0,[4]), ARIMA(0,0,[1,4]), ARIMA([1,4],0,0), ARIMA([1,4],0,1), ARIMA([1,4],0,[4]), dan ARIMA([1,4],0,[1,4]).

Model yang terbentuk dilakukan estimasi parameter dan uji signifikansi parameter untuk setiap parameter dalam model.

Tabel 2. Hasil Uji Signifikansi Parameter ARIMA

Model	Parameter Signifikan
ARIMA (0,0,1)	Ya
ARIMA (1,0,0)	Ya
ARIMA (1,0,1)	Ya
ARIMA (1,0,[4])	Ya
ARIMA (1,0,[1,4])	Ya
ARIMA (0,0,[4])	Ya
ARIMA ([4],0,0)	Ya
ARIMA([4],0,1)	Ya
ARIMA([4],0,[1,4])	Ya
ARIMA([4],0,[4])	Tidak
ARIMA(0,0,[1,4])	Ya
ARIMA([1,4],0,0)	Ya
ARIMA([1,4],0,1)	Ya
ARIMA([1,4],0,[4])	Ya
ARIMA([1,4],0,[1,4])	Tidak

Berdasarkan Tabel 2, diketahui bahwa model dengan parameter signifikan adalah ARIMA(0,0,1), ARIMA(1,0,0), ARIMA(1,0,1), ARIMA(1,0,[4]), ARIMA(1,0,[1,4]), ARIMA(0,0,[4]), ARIMA([4],0,0), ARIMA([4],0,1), ARIMA([4],0,[1,4]), ARIMA([4],0,[4]), ARIMA(0,0,[1,4]), ARIMA([1,4],0,0), ARIMA([1,4],0,1), ARIMA([1,4],0,[4]), dan ARIMA([1,4],0,[1,4]). Model dengan parameter signifikan kemudian dilakukan uji asumsi normalitas residual, uji asumsi independensi residual, dan uji asumsi homoskedastisitas residual

Tabel 3. Hasil Uji Asumsi Residual Model ARIMA

Model	Normalitas Residual	<i>P-Value</i>	Independensi Residual	<i>P-Value</i>	Homoskedastisitas Residual	<i>P-Value</i>
ARIMA(0,0,1)	Tidak Terpenuhi	0,0000	Terpenuhi	0,5390	Tidak Terpenuhi	0,0000
ARIMA(1,0,0)	Tidak Terpenuhi	0,0000	Terpenuhi	0,4773	Tidak Terpenuhi	0,0000
ARIMA(1,0,1)	Tidak Terpenuhi	0,0000	Terpenuhi	0,7861	Tidak Terpenuhi	0,0000
ARIMA(1,0,[4])	Tidak Terpenuhi	0,0000	Terpenuhi	0,6281	Tidak Terpenuhi	0,0000
ARIMA(1,0,[1,4])	Tidak Terpenuhi	0,0000	Terpenuhi	0,9165	Tidak Terpenuhi	0,0000
ARIMA(0,0,[4])	Tidak Terpenuhi	0,0000	Terpenuhi	0,0977	Tidak Terpenuhi	0,0000
ARIMA([4],0,0)	Tidak Terpenuhi	0,0000	Terpenuhi	0,0988	Tidak Terpenuhi	0,0000
ARIMA([4],0,1)	Tidak Terpenuhi	0,0000	Terpenuhi	0,5688	Tidak Terpenuhi	0,0000
ARIMA([4],0,[1,4])	Tidak Terpenuhi	0,0000	Terpenuhi	0,5420	Tidak Terpenuhi	0,0000
ARIMA(0,0,[1,4])	Tidak Terpenuhi	0,0000	Terpenuhi	0,5665	Tidak Terpenuhi	0,0000
ARIMA([1,4],0,0)	Tidak Terpenuhi	0,0000	Terpenuhi	0,6293	Tidak Terpenuhi	0,0000

ARIMA([1,4],0,1)	Tidak Terpenuhi	0,0000	Terpenuhi	0,9238	Tidak Terpenuhi	0,0000
ARIMA([1,4],0,[4])	Tidak Terpenuhi	0,0000	Terpenuhi	0,6039	Tidak Terpenuhi	0,0000


Berdasarkan Tabel 3, dapat dilihat H_0 dari semua uji ditolak untuk semua model karena nilai $p\text{-value} < \alpha$ sehingga dapat disimpulkan bahwa seluruh model ARIMA dengan parameter yang signifikan memiliki korelasi antar lag residual, residual tidak memenuhi normalitas, dan terdapat efek heteroskedastisitas. Efek heteroskedastisitas mengindikasikan adanya efek ARCH/GARCH pada seluruh model yang terbentuk sehingga selanjutnya dilakukan permodelan ARCH dan GARCH.

Nilai AIC digunakan untuk memilih model ARIMA terbaik yang akan dilanjutkan untuk permodelan ARCH/GARCH. Nilai AIC ditampilkan pada Tabel 4.

Tabel 4. Nilai AIC Model ARIMA

Model	AIC
ARIMA (1,0,0)	-2236,95
ARIMA (0,0,1)	-2236,65
ARIMA (1,0,1)	-2238,59
ARIMA (1,0,[4])	-2239,91
ARIMA (1,0,[1,4])	-2238,51
ARIMA (0,0,[4])	-2237,63
ARIMA ([4],0,0)	-2237,39
ARIMA([4],0,1)	-2239,37
ARIMA([4],0,[1,4])	-2238,46
ARIMA(0,0,[1,4])	-2239,75
ARIMA([1,4],0,0)	-2239,54
ARIMA([1,4],0,1)	-2238,37
ARIMA([1,4],0,[4])	-2238,67

Berdasarkan Tabel 1 didapatkan model ARIMA terbaik dengan AIC terkecil, yaitu ARIMA(1,0,[4]). Residual model ARIMA terbaik selanjutnya digunakan untuk mencari model ARCH dan GARCH. Orde model ARCH dan GARCH diidentifikasi menggunakan plot ACF dan PACF berdasarkan residual ARIMA(1,0,[4]) yang disajikan pada Gambar 3.



Gambar 3. Plot ACF dan Plot PACF Kuadrat Residual ARIMA(1,0,[4])

Berdasarkan Gambar3, didapatkan hasil plot ACF dan PACF terpotong pada lag 1,4, dan 7. Model ARCH/GARCH yang diperoleh dari hasil identifikasi model adalah ARIMA(1,0,[4])-ARCH(1), ARIMA(1,0,[4])-ARCH([1,4]), ARIMA(1,0,[4])-ARCH([1,4,7]), ARIMA(1,0,[4])-GARCH(1,1), ARIMA(1,0,[4])-GARCH(1,[1,4]), ARIMA(1,0,[4])-GARCH(1,[1,7]), ARIMA(1,0,[4])-GARCH(1,[1,4,7]), ARIMA(1,0,[4])-GARCH([1,4],1), ARIMA(1,0,[4])-GARCH([1,7],1), dan ARIMA(1,0,[4])-GARCH([1,7],[1,4]).

Model ARCH dan GARCH yang terbentuk dilakukan estimasi dan uji signifikansi untuk setiap parameter model. Hasil uji signifikansi parameter model ARCH dan GARCH dapat dilihat pada Tabel 5.

Tabel 5. Hasil Analisis Model ARCH dan GARCH

Model	Parameter Signifikan	AIC
ARIMA(1,0,[4])-ARCH(1)	Ya	-1,4002
ARIMA(1,0,[4])-ARCH([1,4])	Ya	-1,4082
ARIMA(1,0,[4])-ARCH([1,4,7])	Ya	-1,4131
ARIMA(1,0,[4])-GARCH(1,1)	Ya	-1,4263
ARIMA(1,0,[4])-GARCH(1,[1,4])	Ya	-1,4249
ARIMA(1,0,[4])-GARCH(1,[1,7])	Ya	-1,4249
ARIMA(1,0,[4])-GARCH(1,[1,4,7])	Ya	-1,4235
ARIMA(1,0,[4])-GARCH([1,4],1)	Ya	-1,4250
ARIMA(1,0,[4])-GARCH([1,7],1)	Ya	-1,4249
ARIMA(1,0,[4])-GARCH([1,7],[1,4])	Ya	-1,4236

Berdasarkan Tabel 5, diketahui bahwa semua model memiliki parameter yang signifikan. Model dengan parameter signifikan selanjutnya dilakukan pemilihan model terbaik dengan indikator nilai AIC. Model terbaik memiliki nilai AIC paling kecil (Wei, 2006). Tabel 5 menunjukkan bahwa model terbaik adalah model ARIMA(1,0,[4])-GARCH(1,1) dengan nilai AIC sebesar -1,4263.

Residual model terbaik selanjutnya dikenakan uji *Sign and Size Bias* dan uji independensi residual. Uji *Sign and Size Bias* dilakukan untuk mengetahui apakah terdapat efek asimetris pada residual model. Uji ini terdiri dari uji tanda bias, uji ukuran bias positif, ukuran bias negative, dan uji efek gabungan. Uji independensi residual dilakukan terhadap residual model untuk mengetahui apakah model dapat menggambarkan pergerakan volatilitas data *return* Bitcoin. Hasil uji residual model ARIMA(1,0,[4])-GARCH(1,1) disajikan pada Tabel 6.

Tabel 6. Hasil Uji Residual Model ARIMA(1,0,[4])-GARCH(1,1)

Uji	Hasil Uji
Tanda Bias	Tidak Ditemukan
Ukuran Bias Positif	Tidak Ditemukan
Ukuran Bias Negatif	Tidak Ditemukan
Efek Gabungan	Tidak Ditemukan
Independensi Residual	Terpenuhi

Berdasarkan hasil uji tanda bias, uji ukuran bias positif, dan ukuran bias negative, dan uji efek gabungan pada Tabel 6, didapatkan informasi bahwa residual tidak memiliki efek asimetris. Hal ini juga dapat mengartikan bahwa masalah heteroskedastisitas pada yang terdapat pada model ARIMA ARIMA(1,0,[4]) telah teratasi. Berdasarkan Tabel 6, didapatkan pula informasi bahwa residual model terbaik memenuhi asumsi independensi residual sehingga dapat diartikan model ARIMA ARIMA(1,0,[4]) sesuai untuk menggambarkan pergerakan volatilitas data *return* Bitcoin.

5. KESIMPULAN

Hasil penelitian menunjukkan bahwa terdapat masalah heteroskedastisitas pada data *return* harga bitcoin yang ditunjukkan dengan hasil uji asumsi homoskedastisitas yang tidak signifikan pada semua model ARIMA yang terbentuk. Hal ini membuktikan bahwa

volatilitas yang tinggi dapat mengindikasikan adanya efek heteroskedastisitas. Permodelan ARCH dan GARCH digunakan untuk mengatasi masalah heteroskedastisitas pada data. Model ARCH dan GARCH yang diperoleh adalah model ARIMA(1,0,[4])-ARCH(1), ARIMA(1,0,[4])-ARCH([1,4]), ARIMA(1,0,[4])-ARCH([1,4,7]), ARIMA(1,0,[4])-GARCH(1,1), ARIMA(1,0,[4])-GARCH(1,[1,4]), ARIMA(1,0,[4])-GARCH(1,[1,7]), ARIMA(1,0,[4])-GARCH(1,[1,4,7]), ARIMA(1,0,[4])-GARCH([1,4],1), ARIMA(1,0,[4])-GARCH([1,7],1), dan ARIMA(1,0,[4])-GARCH([1,7],[1,4]). model terbaik adalah model ARIMA(1,0,[4])-GARCH(1,1) dengan nilai AIC sebesar -1,4263 dengan persamaan sebagai berikut.

Persamaan mean:

$$r_t = 1,061 - 0,0541r_{t-1} + a_t - 0,0597a_{t-4}$$

Persamaan varian:

$$\sigma_t^2 = 0,0006 + 0,0498a_{t-1}^2 + 0,9145\sigma_{t-1}^2$$

Berdasarkan hasil uji *Sign and Size Bias* tidak ditemukan adanya efek asimetrisitas pada residual model GARCH untuk data *return* harga Bitcoin. Hasil dari analisis residual model GARCH menunjukkan bahwa model ARIMA(1,0,[4])-GARCH(1,1) sesuai untuk menggambarkan volatilitas data *return* Bitcoin periode 30 Juni 2018 sampai 30 Juni 2022.

DAFTAR PUSTAKA

- Almansour, B. Y., Muneer M. A., dan Ammar Y. A. 2021. *Performance of ARCH and GARCH Models in Forecasting Cryptocurrency Market Volatility*. Industrial Engineering & Management System Vol.20, No. 2: Hal. 130-139. <https://doi.org/10.7232/iems.2021.20.2.130>.
- Bollerslev, T. 1986. *Generalized Autoregressive Conditional Heteroscedasticity*. Journal of Economy Vol. 31, No. 3: Hal. 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1).
- Cryer, J.D. dan Kung S. C. 2008. *Time Series Analysis With Applications in R*. Edisi 2. New York: Springer.
- Daly, K. 2008. *Financial Volatility: Issues and Measuring Techniques*. Physica A: Statistical Mechanics and its Application Vol. 387, No. 11: Hal. 2377-2393. <https://doi.org/10.1016/j.physa.2008.01.009>.
- Engle, R. F. 1982. *Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation*. Econometrica Vol. 50, No. 4: Hal. 987-1007. <https://doi.org/10.2307/1912773>.
- Hayes, A. 2021. *Volatility*. <https://www.investopedia.com/terms/v/volatility.asp>.
- Hyndman, R.J. dan George A. 2018. *Forecasting: Principles and Practice*. Edisi 2. Melbourne, Australia: Otexts. <https://otexts.com/fpp2/>.
- Katsiampa, P. 2017. *Volatility Estimation for Bitcoin: A Comparison of GARCH Model*. Economics Letters Vol. 158: Hal. 3-6. <https://doi.org/10.1016/j.econlet.2017.06.023>.
- Khairunnisa, D. E., Budi P., dan Wita J. E. 2022. *Currency Risk Analysis During the Covid-19 Pandemic: Value at Risk (VaR) Approach*. Jurnal Manajemen dan Organisasi (JMO) Vol.13, No.1: Hal. 61-73. <https://doi.org/10.29244/jmo.v13i1.40428>.
- Makridakis, S., Wheelwright, S. C., Hyndman, R. J. 1998. *Forecasting: Methods and Applications*. Edisi 3. New York: John Willey & Sons, Inc.

- Naimy, V., O., Gema G., E. dan Rim E. K. 2021. *The Predictive Capacity of GARCH-type Models in Measuring The Volatility of Crypto and Word Currencies*. PLoS ONE Vol. 16, No. 1: Hal. 1-17. <https://doi.org/10.1371/journal.pone.0245904>.
- Ngunyi, A., Mundia, S. M., dan Cyprian O. O. 2019. *Modelling Volatility Dynamics of Cryptocurrencies Using GARCH Models*. Journal of Mathematical Finance Vol. 9, No. 4: Hal. 591-615. <https://doi.org/10.4236/jmf.2019.94030>.
- Saluza, I. 2017. *Model Estimasi GARCH dalam Mengukur Kinerja Nilai Tukar Rupiah*. Eksakta Vol. 18, No. 2: Hal. 52-61. <https://eksakta.ppj.unp.ac.id/index.php/eksakta/article/view/53>.
- Tomšik, R. 2019. *Power Comparisons of Shapiro-Wilk, Kolmogorov-Smirnov and Jarque-Bera Tests*. Scholars Journal of Research in Mathematics and Computer Science Vol. 3, No. 3: Hal. 238-243. <https://www.scischolars.com/journals/index.php/sjrmcs/article/download/248/pdf>.
- Wei, W.W.S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. Edisi 2. New York: Pearson Addison Wesley.