

PERAMALAN VOLATILITAS *RETURN CRYPTOCURRENCY* MENGGUNAKAN MODEL *ASYMMETRIC GENERALIZED AUTOREGRESSIVE HETEROSCEDASTICITY (GARCH)*

Haasya Wafdayanti^{1*}, Mustafid², Suparti³

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

*e-mail: haasyawafdayanti04@gmail.com

DOI: 10.14710/j.gauss.14.1.224-235

Article Info:

Received: 2024-08-13

Accepted: 2025-07-29

Available Online: 2025-07-30

Keywords:

*Return; Volatility; Forecasting;
BNB-USD; Asymmetric GARCH*

Abstract: Cryptocurrency is a digital asset that has high level of risk and high rate of return so that it attracts many investors to invest. Risk is described as volatility, forecasting volatility can be a consideration for investors in viewing risks and making decisions in investment activities. High volatility raises the problem of non-constant residual variance (heteroscedasticity) so that the ARIMA model can't be used to predict volatility. ARCH/GARCH models provide a solution for predicting volatility, but when applied to financial data, there is an asymmetric effect involving different positive and negative residuals. Therefore, this research aims to anticipate the variation of returns for the next 7 days using asymmetric GARCH models (EGARCH, TGARCH, APARCH). Volatility is represented using daily return BNB-USD data from March 2nd, 2020 to February 4th, 2023. The results show that the TGARCH (1,1) model is the best-performing model with RMSE value obtained is 0,00653, MAE value obtained 0,00591, and SMAPE value obtained is 19,53%, which is in the range between 10% and 20%. It means model has good forecasting performance. Data analysis equipped with GUI-R can make it easier for investors to obtain forecasts of return volatility.

1. PENDAHULUAN

Cryptocurrency menjadi suatu fenomena yang marak diperbincangkan dan menarik banyak perhatian masyarakat. Memasuki bulan September 2022, Badan Pengawas Berjangka Komoditi (BAPPEBTI) mencatat total investor kripto mencapai 16,27 juta investor dimana nilai ini lebih besar daripada total pemodal di bursa efek yang meraih 10,3 juta pemodal menurut data Bursa Efek Indonesia (BEI). Transaksi yang lebih bebas dan cepat menjadi salah satu keunggulan *cryptocurrency* karena tidak adanya otoritas sentral yang mengatur mata uang ini. *Cryptocurrency* memiliki kelemahan yaitu memiliki volatilitas yang tinggi dimana harga aset digital tersebut mengalami kenaikan dan penurunan harga yang cepat sehingga sangat berisiko apabila dijadikan alternatif investasi (Hartono dan Budiarsih, 2022). Semakin tinggi volatilitas *return* suatu aset dapat menyebabkan tingkat keuntungan yang tinggi dan juga tingkat kerugian yang tinggi pula. Pembuatan model yang dapat digunakan untuk memprediksi volatilitas *return* suatu aset kripto diperlukan sehingga hasil peramalan volatilitas dapat menjadi pedoman untuk pemodal saat berinvestasi.

Keberadaan volatilitas memberikan permasalahan heteroskedastisitas pada varian residual. Model ARIMA tidak bisa digunakan untuk melihat fenomena volatilitas tinggi karena model tersebut mengasumsikan varian residual yang konstan. Engle (1982) memperkenalkan model ARCH, sedangkan Bollerslev dan Taylor (1986) mengembangkan model GARCH sebagai perluasan dari ARCH. Model ARCH/GARCH mengasumsikan efek simetris dari residual pada volatilitas, sehingga pada data keuangan yang menunjukkan adanya perbedaan residual pada volatilitas atau adanya efek asimetris (*leverage effect*)

diperlukan pemodelan dengan menggunakan model GARCH asimetris. Tiga model GARCH asimetris yang digunakan adalah model EGARCH, TGARCH, dan APARCH.

Penelitian sebelumnya telah dilakukan oleh Khodir (2020) yang mengkaji volatilitas mata uang kripto menggunakan model GARCH untuk mengestimasi *Value at Risk* dengan bantuan Eviews 10 dan Microsoft Excel. Penelitian tersebut bertujuan untuk meramalkan volatilitas untuk 1 periode ke depan sehingga masih terbatas dalam menangkap efek asimetris dan melihat evaluasi kinerja model dalam melakukan prediksi. Berdasarkan penelitian tersebut, maka pada penelitian ini akan bertujuan untuk meramalkan volatilitas harian *return* dari aset *cryptocurrency* yang memiliki efek asimetris dengan model GARCH asimetris selama 7 hari ke depan disertai dengan pembangunan GUI-R. Model GARCH asimetris yang digunakan terdiri dari model EGARCH, TGARCH, dan APARCH.

2. TINJAUAN PUSTAKA

Cryptocurrency adalah satu diantaranya jenis pembayaran virtual yang menjadi aset digital berbasis kode kriptografik sehingga sangat sulit untuk dilakukan pembajakan dan digandakan. Sistem mata uang virtual dikembangkan dengan sistem yang terdesentralisasi *blockchain*. *Blockchain* merupakan suatu teknologi pembukuan yang terdistribusi (*Distributed Ledger Technology/DLT*) yang mana setiap anggota yang sudah terkoneksi dalam jaringan dapat memiliki akses dalam pembukuan tersebut. *Cryptocurrency* merupakan salah satu aset yang memiliki volatilitas tinggi sehingga termasuk dalam kategori *high risk financial instrument* apabila digunakan sebagai penyimpanan nilai.

Investasi adalah tindakan menyimpan modal dalam bentuk uang atau aset lainnya pada suatu objek untuk mendapatkan keuntungan dalam periode tertentu. Sebelum melakukan investasi, penting bagi investor untuk memahami hubungan antara *return* dan risiko. *Return* adalah keuntungan yang diperoleh dari investasi yang dapat dihitung dengan menggunakan rumus *Continuous Compounding Return* pada persamaan (1) (Zivot, 2015).

$$R_t = \ln(X_t) - \ln(X_{t-1}) \quad (1)$$

R_t merupakan *return* harga penutupan aset saat waktu ke-t, X_t adalah harga penutupan aset pada waktu ke-t, dan X_{t-1} adalah harga penutupan aset pada waktu t-1.

Risiko dapat diinterpretasikan sebagai perbedaan antara perkiraan pendapatan dan pendapatan aktual yang diperoleh. Standar deviasi dari tingkat *return* adalah ukuran dari risiko yang disebut dengan volatilitas. Tsay (2005) menyatakan bahwa untuk menghitung volatilitas harian suatu aset tidak bisa terobservasi karena dalam 1 hari hanya terdapat 1 observasi. Apabila terdapat data *intraday* dengan frekuensi tinggi maka data tersebut dapat digunakan untuk mengestimasi volatilitas harian. Andersen *et al.* (2001) menyatakan bahwa volatilitas harian suatu aset dapat diestimasi dengan *intradaily log return* dimana μ_t diasumsikan bernilai 0 sehingga dapat diperoleh nilai *realized variance* yang digunakan untuk memperoleh *realized volatility* yang dapat dinyatakan pada persamaan (2).

$$RVOL_t^{(n)} = \sqrt{RV_t^{(n)}} \text{ dengan } RV_t^{(n)} = \sum_{i=1}^n R_{t,i}^2 \quad (2)$$

dengan $RV_t^{(n)}$ adalah *realized variance* aset pada waktu ke t dengan n pengamatan, $RVOL_t^{(n)}$ adalah *realized volatility* aset pada waktu ke t dengan n pengamatan, dan $R_{t,i}^2$ adalah nilai kuadrat *return* aset ke-t pada pengamatan ke-i.

Analisis runtun waktu digunakan untuk melakukan analisis data yang mempertimbangkan pengaruh waktu, dimana pengamatan sekarang (R_t) tergantung pada k pengamatan sebelumnya (R_{t-k}) dengan $k = 1, 2, \dots, p$. Dalam analisis runtun waktu, data harus memenuhi stasioneritas dimana tidak terjadi perubahan yang signifikan pada saat data berfluktuasi. Data yang stasioner memiliki varian yang konstan dan persebaran data yang

berada di mean yang konstan. Menurut Wei (2006), ada dua jenis stasioneritas, yaitu stasioneritas dalam varian dan stasioneritas dalam mean.

Stasioneritas data dalam varian diuji dengan pengujian Box-Cox untuk melihat transformasi data. Apabila terdapat variabel yang diamati pada waktu ke-t atau R_t , seperti *return*, Box dan Cox (1964) memperkenalkan transformasi dalam bentuk persamaan (3).

$$R_t^{(\lambda_1)} = \begin{cases} \frac{(R_t + \lambda_2)^{\lambda_1} - 1}{\lambda_1} & (\lambda_1 \neq 0) \\ \log(R_t + \lambda_2) & (\lambda_1 = 0) \end{cases} \quad (3)$$

dimana R_t adalah variabel yang diamati pada waktu ke-t, λ_1 nilai transformasi Box Cox, dan λ_2 adalah konstanta. Nilai $R_t + \lambda_2$ harus bernilai positif dengan memilih nilai λ_2 yang tepat berdasarkan nilai R_t yang minimum (Amir *et al.*, 2008). Apabila nilai lamda = 1, maka data sudah stasioner dalam varian, sedangkan apabila nilai lamda $\neq 1$, maka data tidak stasioner dalam varian sehingga harus dilakukan transformasi (Box dan Cox, 1964).

Stasioneritas dalam mean terpenuhi apabila data runtun waktu berfluktuasi di sekitar nilai rata-rata yang konstan. Salah satu pengujian stasioneritas data dalam mean menggunakan uji akar unit (*unit root test*) dengan menggunakan uji *Augmented Dickey-Fuller* (ADF). Pengujian akar unit *Augmented Dickey Fuller* (ADF) dilakukan dengan menguji hipotesis pada persamaan (4).

$$\Delta R_t = \beta_1 + \beta_2 t + \delta R_{t-1} + e_t \text{ dengan } t=1,2,3,\dots,n \text{ dimana } \Delta R_t = R_t - R_{t-1} \quad (4)$$

dimana t adalah trend waktu, β_1, β_2, δ adalah konstanta model.

a. Uji Hipotesis

H_0 : $\delta = 0$ (terdapat akar unit sehingga data tidak stasioner)

H_1 : $\delta \neq 0$ (tidak terdapat akar unit sehingga data stasioner)

b. Statistik Uji

$t_{hitung} = \frac{\hat{\delta}}{SE(\hat{\delta})}$, dengan $\hat{\delta}$ adalah penaksir kuadrat terkecil dari δ dan $SE(\hat{\delta})$ adalah standard error dari δ .

c. Daerah Penolakan

Tolak H_0 jika $|t_{hitung}| > t_{tabel}(t_{(\alpha, n-1)})$ atau p-value $< \alpha$.

Selain menggunakan plot ACF dan PACF, dalam perangkat lunak R, pembentukan model ARIMA juga dapat melalui penggunaan fungsi `auto.arima()`. Menurut Rosadi (2008), fungsi `auto.arima()` dapat digunakan untuk mendapatkan model ARIMA terbaik. Fungsi `auto.arima()` menggunakan algoritma Hyndman-Khandar untuk menentukan nilai p dan q dengan meminimalkan AIC setelah dilakukan differensi d dalam menentukan model ARIMA terbaik. Jenis model runtun waktu yang digunakan dalam penelitian yaitu:

a. Model *Autoregressive* atau AR (p)

$$R_t = \phi_1 R_{t-1} + \phi_2 R_{t-2} + \dots + \phi_p R_{t-p} + e_t \quad (5)$$

b. Model *Moving Average* atau MA (q)

$$R_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (6)$$

c. Model *Autoregressive Moving Average* atau ARMA (p,q)

$$R_t = \phi_1 R_{t-1} + \dots + \phi_p R_{t-p} - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} + e_t \quad (7)$$

d. Model Model *Autoregressive Integrated Moving Average* atau ARIMA (p,d,q)

$$\phi_p(B)(1-B)^d R_t = \theta_0 + \theta_q(B)e_t \quad (8)$$

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p) \text{ dan } \theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$$

dimana R_t adalah nilai variabel pada waktu ke-t, $\phi_1, \phi_2, \dots, \phi_p$ adalah koefisien dari model AR(p), $\theta_1, \theta_2, \dots, \theta_q$ adalah koefisien dari model MA(q), e_t nilai kesalahan pada waktu ke-t dengan $e_t \sim NID(0, \sigma^2)$, $\phi_p(B)$ adalah operator AR(p), dan $\theta_q(B)$ adalah operator MA(q).

Estimasi parameter model ARIMA Box Jenkins dilakukan dengan menggunakan metode maksimum likelihood dengan mensyaratkan *error* berdistribusi normal $e_t \sim NID(0, \sigma^2)$. Faktanya pada data keuangan sering kali dijumpai residual tidak berdistribusi secara normal, sehingga terjadi kesalahan dalam pemodelan. Oleh karena itu, Lee (2004) mengusulkan metode *quasi maksimum likelihood* (QML) dalam mengestimasi parameter model melalui pemaksimalan fungsi *likelihood*. Melalui metode QML, ARCH/GARCH dapat memberikan model yang layak dan parameter yang konsisten.

Model ARIMA yang telah terbentuk harus memenuhi tahapan verifikasi model yang terdiri dari pengujian asumsi nonautokorelasi residual, asumsi normalitas residual, dan asumsi homoskedastisitas residual. Pada pengujian asumsi nonautokorelasi, model ARIMA diasumsikan bahwa autokorelasi tidak terdapat dalam residual model. Pengujian untuk asumsi nonautokorelasi dapat diuji melalui Ljung Box-Pierce (Q) (Wei, 2006).

a. Uji Hipotesis

H_0 : $\rho_1 = \rho_2 = \dots = \rho_k = 0$ (tidak ada korelasi antar lag residual)

H_1 : paling sedikit ada satu $\rho_k \neq 0$ dengan $k = 1, 2, 3, \dots, p$ (terdapat korelasi antar lag residual)

b. Statistik Uji

$$Q = n(n+2) \sum_{k=1}^p \frac{\rho_k^2}{n-k} \text{ dimana } \rho_k = \frac{\text{cov}(R_t, R_{t-k})}{[\text{var}(R_t) \cdot \text{var}(R_{t-k})]^{\frac{1}{2}}} = \frac{\text{cov}(R_t, R_{t-k})}{[\{\text{var}(R_t)\}^2]^{\frac{1}{2}}} = \frac{\hat{\gamma}_k}{\hat{\gamma}_0}$$

dimana n merupakan total pengamatan, ρ_k merupakan koefisien autokorelasi residual pada lag- k , dan p adalah lag maksimum.

c. Daerah Penolakan

Tolak H_0 jika $Q > \chi^2_{(\alpha, df=p)}$ jika p merupakan lag maksimum atau tolak H_0 jika $p\text{-value} < \alpha$. Asumsi terpenuhi jika tidak terdapat korelasi antar lag residual.

Pengujian asumsi normalitas residual dilakukan dengan menggunakan uji Jarque Bera untuk melihat residual model ARIMA mengikuti distribusi normal atau tidak.

a. Uji Hipotesis

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

b. Statistik Uji

$JB = \frac{n}{6} (S^2 + \frac{(K-3)^2}{4})$ dimana statistik uji Jarque Bera terdistribusi χ^2 mengikuti derajat bebas dua serta n adalah banyaknya pengamatan, K adalah *kurtosis*, dan S adalah *skewness*.

c. Daerah Penolakan

Tolak H_0 jika $JB > \chi^2_{(\alpha, 2)}$ atau tolak H_0 jika $p\text{-value} < \alpha$. Asumsi terpenuhi jika residual berdistribusi secara normal.

Kemudian model ARIMA akan diuji untuk asumsi homoskedastisitas residual. Uji ARCH-Lagrange Multiplier (ARCH-LM) digunakan untuk mengidentifikasi keberadaan ketidakkonstanan dalam varian data atau heteroskedastisitas. Uji ini berguna dalam mendeteksi efek ARCH pada data. Pengujian ARCH-LM berdasarkan persamaan ARCH oleh Engle yang dinyatakan pada persamaan (9).

$$\varepsilon_t^2 = a_0 + a_1 \varepsilon_{t-1}^2 + \dots + a_p \varepsilon_{t-p}^2 + u_t \quad (9)$$

Langkah pengujian uji ARCH-LM adalah sebagai berikut:

a. Uji Hipotesis

H_0 : $a_1 = a_2 = \dots = a_p = 0$ (tidak ada efek ARCH pada residual sampai lag ke- p)

H_1 : minimal ada satu nilai $a_k \neq 0$ untuk $k = 1, 2, 3, \dots, p$ (terdapat efek ARCH sampai lag ke- p)

b. Statistik Uji

$LM = nR^2 \sim \chi_p^2$, dengan n merupakan jumlah pengamatan dan R^2 adalah koefisien determinasi.

c. Daerah Penolakan

Tolak H_0 jika $LM > \chi^2_{(p)}$ atau p-value $< \alpha$. Asumsi terpenuhi jika tidak terdapat efek ARCH pada residual.

Menurut Tsay (2005), volatilitas merujuk pada fluktuasi perubahan harga suatu aset. Volatilitas dapat diukur dengan standar deviasi dari *return* aset. Pada data keuangan sering terjadi kasus heteroskedastisitas, sehingga model ARIMA tidak dapat digunakan karena mengasumsikan residual yang konstan. Oleh karena itu, pada kondisi ini diperlukan model volatilitas runtun waktu untuk pemodelan.

a. Model ARCH (m) (*Autoregressive Conditional Heteroskedasticity*) oleh Engle (1982)

$$\sigma_t^2 = a_0 + a_1 \varepsilon_{t-1}^2 + \dots + a_m \varepsilon_{t-m}^2 \quad \varepsilon_t = \sigma_t \varepsilon_t \text{ dengan } \varepsilon_t \sim iid(0,1) \quad (10)$$

dengan koefisien parameter harus memenuhi $a_0 > 0$ dan $a_i \geq 0$ dengan $i = 1, \dots, m$.

b. Model GARCH (m,s) (*Generalized Autoregressive Conditional Heteroskedasticity*) oleh Tsay (2005)

$$\sigma_t^2 = a_0 + \sum_{i=1}^m a_i \varepsilon_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2 \quad \varepsilon_t = \sigma_t \varepsilon_t \text{ dengan } \varepsilon_t \sim iid(0,1) \quad (11)$$

dengan koefisien parameter harus memenuhi $a_0 > 0$, $a_i \geq 0$, $\beta_j \geq 0$, dan

$$0 < (a_i + \beta_j) < 1.$$

Pada data runtun waktu, dapat terjadi respon volatilitas yang asimetris terhadap residual positif dan negatif yang disebut dengan *leverage effect* atau efek asimetris. Pemodelan GARCH tidak dapat digunakan dalam memodelkan efek asimetris sehingga perlu dilakukan pemodelan GARCH asimetris. Setelah dimodelkan, model ARCH/GARCH perlu dilakukan uji homoskedastisitas residual sebagai syarat kecukupan model.

a. Model EGARCH (m,s) (*Exponential GARCH*) oleh Tsay (2005)

$$\ln \sigma_t^2 = a_0 + \sum_{j=1}^s \beta_j \ln(\sigma_{t-j}^2) + \sum_{i=1}^m a_i \left| \frac{\varepsilon_{t-i}}{\sigma_{t-i}} \right| + \sum_{k=1}^m \gamma_i \frac{\varepsilon_{t-k}}{\sigma_{t-k}} \quad (12)$$

$$\varepsilon_t = \sigma_t \varepsilon_t, \varepsilon_t \sim iid(0,1)$$

dengan koefisien parameter harus memenuhi $|\beta_j| < 1$ dan γ_i sebagai *leverage effect* harus memenuhi $\gamma_i < 0$ dan $\gamma_i < a_i < -\gamma_i$.

b. Model TGARCH (m,s) (*Threshold GARCH*) oleh Zakoian (1994)

$$\sigma_t^2 = a_0 + \sum_{i=1}^m a_i \varepsilon_{t-i}^2 + \sum_{i=1}^m \gamma_i N_{t-i} \varepsilon_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2 \quad (13)$$

N_{t-i} adalah variabel *dummy* yang menjadi indikator untuk negatif ε_{t-i} :

$$N_{t-i} = \begin{cases} 1, & \text{jika } \varepsilon_{t-i} < 0 \\ 0, & \text{jika } \varepsilon_{t-i} \geq 0 \end{cases}$$

dengan koefisien parameter harus memenuhi $a_0 > 0$, $a_i \geq 0$, $\beta_j \geq 0$ dan γ_i menyatakan *leverage effect* dengan nilai γ_i harus memenuhi $\gamma_i > 0$.

c. Model APARCH (m,s) (*Asymmetric Power ARCH*) oleh Francq dan Zakoian (2019)

$$\sigma_t^\delta = a_0 + \sum_{i=1}^m a_i (|\varepsilon_{t-i}| - \gamma_i \varepsilon_{t-i})^\delta + \sum_{j=1}^s \beta_j \sigma_{t-j}^\delta \quad (14)$$

dengan koefisien parameter harus memenuhi $a_0 > 0$, $a_i > 0$, $\beta_j > 0$, $\delta > 0$, dan $-1 < \gamma_i < 1$.

Dalam mengevaluasi adanya efek asimetris pada data, dilakukan Uji Sign Bias pada residual model GARCH. Pengujian efek asimetris dilakukan berdasarkan persamaan (15) sebagaimana dijelaskan oleh Brook (2008).

$$\hat{\varepsilon}_t^2 = \varphi_0 + \varphi_1 S_{t-1}^- + \varphi_2 S_{t-1}^- \hat{\varepsilon}_{t-1} + \varphi_3 S_{t-1}^+ \hat{\varepsilon}_{t-1} + u_t, \text{ dengan } S_{t-1}^+ = 1 - S_{t-1}^- \quad (15)$$

Pengujian sign bias dapat dilakukan secara individual menggunakan persamaan model (15) dan secara simultan melalui joint effect. Joint effect menandakan bahwa selain guncangan positif dan negated yang berpengaruh pada volatilitas, besarnya guncangan juga dapat mempengaruhi volatilitas.

a. Uji Hipotesis

Pengujian secara individual:

H_0 : $\varphi_1 = 0, \varphi_2 = 0, \varphi_3 = 0$ (residual bersifat simetris)

H_1 : $\varphi_j \neq 0, \varphi_2 \neq 0, \varphi_3 \neq 0$ (residual bersifat asimetris)

Pengujian secara simultan:

H_0 : $\varphi_1 = \varphi_2 = \varphi_3 = 0$ (residual bersifat simetris)

H_1 : paling sedikit terdapat $\varphi_j \neq 0$ dengan $j=1,2,3$ (residual bersifat asimetris)

b. Statistik Uji

Statistik uji pengujian secara individual:

$t = \frac{\hat{\varphi}_j}{SE(\hat{\varphi}_j)}$, dengan $\hat{\varphi}_j$ adalah penaksir kuadrat terkecil dari parameter sign bias dan

$SE(\hat{\varphi}_j)$ adalah standar error dari $\hat{\varphi}_j$.

Statistik uji pengujian secara simultan:

$LM = nR^2 \sim \chi_p^2$, dengan n merupakan jumlah pengamatan dan R^2 adalah koefisien determinasi.

c. Daerah Penolakan

Pengujian individual: tolak H_0 jika $|t_{hitung}| > t_{(\frac{\alpha}{2}, n)}$ atau $p - value < \alpha$.

Pengujian simultan: tolak H_0 jika $LM > \chi^2_{(p)}$ atau $p - value < \alpha$

Model terbaik dipilih berdasarkan besaran *Akaike's Information Criterion* (AIC) yang paling sedikit dari setiap model yang terbentuk. Rumus untuk memperoleh nilai AIC dapat dinyatakan dalam persamaan (16) (Rosadi, 2012).

$$AIC = n \log \left(\frac{SSR}{n} \right) + 2k \quad (16)$$

dengan n merupakan banyaknya sampel, $SSR = \sum_{t=1}^n \hat{e}_t^2$ untuk model ARIMA sedangkan $SSR = \sum_{i=1}^n \hat{\varepsilon}_i^2$ untuk model GARCH, dan k merupakan banyaknya parameter pada model.

Pada penelitian ini akan menggunakan nilai MSE (*Mean Square Error*) dan RMSE (*Root Mean Square Error*) sebagai ukuran evaluasi kinerja model untuk menentukan model terbaik di antara model GARCH asimetris yang digunakan untuk peramalan. Sedangkan, untuk mengukur akurasi peramalan akan digunakan nilai SMAPE. Apabila akan diramalkan data volatilitas harian dengan n periode peramalan, dimana σ_t menyatakan data asli, $\hat{\sigma}_t$ adalah data peramalan, dan n merupakan jumlah data yang diprediksi maka:

a. RMSE (*Root Mean Square Error*)

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (\sigma_t - \hat{\sigma}_t)^2}{n}} \quad (17)$$

b. MAE (*Mean Absolute Error*)

$$MAE = \frac{1}{n} \sum_{t=1}^n |\sigma_t - \hat{\sigma}_t| \quad (18)$$

c. SMAPE (*Symmetric Mean Absolute Percentage Error*)

SMAPE diperkenalkan sebagai pengganti MAPE. SMAPE menjadi solusi dalam masalah data aktual yang nilainya mendekati nol sehingga besarnya nilai mutlak error ketika data aktual lebih besar daripada data peramalan dapat dihindari.

$$SMAPE = \frac{2}{n} \sum_{t=1}^n \frac{|\sigma_t - \hat{\sigma}_t|}{(|\sigma_t| + |\hat{\sigma}_t|)} \times 100\% \quad (19)$$

Kriteria nilai MAPE yang juga digunakan untuk kriteria nilai SMAPE dapat dilihat pada Tabel 1 sebagai berikut: (Chang *et al.*, 2007).

Tabel 1. Kriteria nilai SMAPE

SMAPE	Pengertian
SMAPE < 10%	Kemampuan peramalan sangat baik
10% ≤ SMAPE < 20%	Kemampuan peramalan baik
20% ≤ SMAPE < 50%	Kemampuan peramalan cukup
SMAPE ≥ 50%	Kemampuan peramalan buruk

3. METODE PENELITIAN

Penelitian ini akan menggunakan data kuantitatif yang akan diklasifikasikan ke dalam dua bagian, yakni data *in sample* dan data *out sample*. Data penelitian ini memakai data sekunder yang diperoleh dari situs web Yahoo Finance. Data *in sample* yang digunakan adalah data *return* dari *closing price* BNB-USD periode 02 Maret 2020 – 04 Februari 2023 sebanyak 1.071 data. Sedangkan data *out sample* yang digunakan adalah data volatilitas harian *return* BNB-USD yang diperoleh dari data *intraday closing price* BNB-USD dengan frekuensi 30 menit dalam 1 hari untuk periode 05 Februari 2023 – 11 Februari 2023. Langkah analisis data yang akan dilakukan adalah sebagai berikut:

- a. Menghitung nilai volatilitas harian *return* BNB-USD dengan menggunakan rumus *realized volatility* pada persamaan (2) dengan Microsoft Excel.
- b. Melakukan input data *closing price* BNB-USD dan menghitung *return* harian dengan rumus *Continuous Compounding Return* pada persamaan (1).
- c. Melakukan analisis deskriptif dari data *return* harian BNB-USD sebagai data *in sample*.
- d. Melakukan uji stasioneritas data *return* harian BNB-USD dalam mean dan juga varian.
- e. Mencari model terbaik melalui menggunakan fungsi `auto.arima()`.
- f. Mencari estimasi parameter model ARIMA(p,q) dan menguji signifikansi parameter model ARIMA(p,q). Apabila terdapat parameter model ARIMA(p,q) yang tidak signifikan maka akan dilakukan pemodelan ulang dengan hanya menggunakan parameter-parameter model yang signifikan.
- g. Melakukan tahapan verifikasi model yaitu melalui pengujian asumsi nonautokorelasi, asumsi normalitas, dan asumsi homoskedastisitas pada residual model ARIMA(p,q).
- h. Melakukan identifikasi model GARCH(m,s) apabila residual model ARIMA(p,q) tidak memenuhi asumsi homoskedastisitas residual. Mencari estimasi parameter model GARCH(m,s), pengujian signifikansi parameter model, pengecekan syarat kecukupan koefisien parameter model GARCH (m,s), serta menguji asumsi homoskedastisitas residual model GARCH(m,s) sebagai syarat kecukupan model.
- i. Melakukan uji sign bias pada model GARCH(m,s).
- j. Mengidentifikasi model GARCH asimetris apabila terdapat efek asimetris. Model GARCH asimetris yang akan digunakan adalah model EGARCH, TGARCH, dan APARCH. Mencari estimasi parameter model GARCH asimetris yang terbentuk, pengujian signifikansi parameter model, pengecekan syarat kecukupan koefisien parameter model GARCH asimetris, dan menguji asumsi homoskedastisitas residual model GARCH asimetris sebagai syarat kecukupan model.
- k. Menentukan model terbaik dari masing-masing model GARCH asimetris dengan melihat uji signifikansi parameter, verifikasi model, dan nilai AIC yang diperoleh.

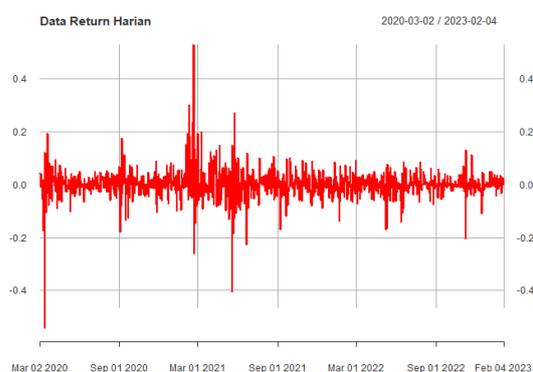
- l. Meramalkan nilai volatilitas harian *return* BNB-USD selama 7 periode ke depan dari 3 model GARCH asimetris yang terbentuk serta mencari nilai RMSE dan MSE untuk melihat model GARCH asimetris yang paling sesuai untuk peramalan volatilitas.
- m. Mencari nilai SMAPE untuk melihat kemampuan model untuk meramalkan volatilitas *return* BNB-USD selama 7 periode ke depan.

4. HASIL DAN PEMBAHASAN

Data sekunder penelitian ini adalah data *closing price* BNB-USD periode 01 Maret 2020 – 04 Februari 2023 yang mengalami fluktuasi seiring dengan berjalannya waktu. Pergerakan data *closing price* BNB-USD dapat dilihat pada Gambar (1). Dengan menggunakan rumus *Continuous Coumpounding Return* dapat diperoleh data *return* harian BNB-USD periode 02 Maret 2020 – 04 Februari 2023 yang digunakan dalam pemodelan. Pergerakan data *return* BNB-USD dapat dilihat pada Gambar (2).



Gambar 1. Grafik Pergerakan *Closing Price* BNB-USD



Gambar 2. Grafik Pergerakan *Return* BNB-USD

Data *return* BNB-USD yang sudah diperoleh kemudian dianalisis dengan menggunakan statistika deskriptif agar bisa mengetahui karakteristik atau gambaran umum dari data *return* BNB-USD yang akan dimodelkan. Dari analisis statistika deskriptif, didapatkan hasil berikut: nilai terendah (minimum) adalah -0,543084, nilai tengah (median) adalah 0,001969, nilai rata-rata (mean) adalah 0,002671, nilai tertinggi (maksimum) adalah 0,529218, *skewness* memiliki nilai -0,2867613, *kurtosis* memiliki nilai 23,30267, dan standar deviasi memiliki nilai 0,05612203.

Pengujian stasioneritas data *return* BNB-USD dilakukan dengan dua kriteria. Pertama, menggunakan uji Box-Cox guna menilai stasioneritas dalam varian. Kedua, melalui pengujian *Augmented Dickey Fuller* untuk menguji stasioneritas dalam mean. Menurut Box dan Cox (1964), apabila suatu data yang akan diuji bernilai negatif maka transformasi dilakukan dengan menambahkan nilai λ_2 . Nilai λ_2 yang ditambahkan harus membuat data bernilai positif (Amir *et al.*, 2008). Berdasarkan nilai statistika deskriptif, diperoleh nilai minimum pada data *return* BNB-USD sebesar -0,543084 sehingga perlu dilakukan penambahan nilai λ_2 sebesar 0,6 agar semua data bernilai positif. Nilai lamda yang diperoleh setelah melakukan Box Cox test sebesar 1 ($\lambda = 1$), sehingga data *return* BNB-USD telah stasioner dalam varian. Kemudian pada pengujian ADF test, diperoleh nilai p-value = 0,01. Pada taraf signifikansi 5%, data *return* BNB-USD telah stasioner dalam mean karena menolak H_0 dengan nilai nilai p-value $< \alpha$.

Model ARIMA terbaik yang diperoleh dari data *return* BNB-USD dengan penggunaan `auto.arima()` adalah model ARIMA(1,0,1) dengan *non-zero mean* atau ARMA(1,1) dengan konstanta. Setelah melalui tahapan estimasi parameter dan juga uji signifikansi parameter model, pada model ARMA(1,1) terdapat parameter yang tidak signifikan yaitu parameter θ_0 atau konstanta, sehingga parameter tersebut tidak dapat dimasukkan ke dalam

pemodelan sehingga akan dilakukan pemodelan ulang dengan hanya menggunakan parameter-parameter model yang signifikan. Model akhir ARMA(1,1) setelah dimodelkan ulang dapat diperoleh pada persamaan berikut:

$$R_t = -0,80739R_{t-1} - 0,7221e_{t-1} + e_t$$

Model ARMA(1,1) tersebut merupakan *mean* model atau model *return* rata-rata dari pemodelan *return* BNB-USD.

Model ARMA(1,1) akan dilakukan pengujian untuk melihat pemenuhan asumsi pada tahapan verifikasi model. Pada pengujian asumsi nonautokorelasi residual, berdasarkan hasil pengolahan data diperoleh nilai $Q = 0,092574$ dengan $p\text{-value} = 0,7609$. Pada taraf signifikansi 5%, model ARMA(1,1) gagal menolak H_0 karena nilai $p\text{-value} > \alpha$ sehingga dalam model ARMA(1,1) tidak ada korelasi antar lag residual dan model ARMA(1,1) memenuhi asumsi nonautokorelasi residual.

Kemudian pada pengujian asumsi normalitas residual, berdasarkan hasil pengolahan data diperoleh nilai $JB = 19.887$ dan $p\text{-value} < 2,2e-16$. Pada taraf signifikansi 5%, residual model ARMA (1,1) menolak H_0 karena nilai $p\text{-value} < \alpha$ sehingga residual model ARMA(1,1) tidak berdistribusi secara normal atau tidak memenuhi asumsi normalitas residual. Model ARMA(1,1) yang tidak memenuhi asumsi normalitas residual menjadi salah satu indikasi terdapat *fat tails/heavy tails* atau kecenderungan lebih besar untuk terjadi kejadian ekstrem. *Fat tails/heavy tails* atau bisa juga disebut dengan leptokurtik merupakan salah satu ciri khas data keuangan di samping adanya *volatility clustering* dan ketidakasimetrisan.

Pada tahapan pengujian asumsi homoskedastisitas residual, berdasarkan hasil pengolahan data diperoleh nilai $LM = 3.318,0121$ dan $p\text{-value} = 0$. Pada taraf signifikansi 5%, residual model ARMA(1,1) menolak H_0 karena $p\text{-value} < \alpha$ sehingga terdapat efek ARCH dalam model dan model ARMA(1,1) tidak memenuhi asumsi homoskedastisitas residual atau terjadi heteroskedastisitas sehingga perlu untuk dilakukan pemodelan ARCH/GARCH.

Menurut Rosadi (2011), dalam pemodelan GARCH(m,s), alternatif yang dapat digunakan adalah memilih orde m serta s sebesar m dan $s \leq 2$ untuk menghindari pemodelan volatilitas dengan orde yang tinggi sehingga dalam penelitian ini dapat dibentuk beberapa model yaitu model ARMA(1,1)-GARCH(1,1), ARMA(1,1)-GARCH(1,2), ARMA(1,1)-GARCH(2,1), dan ARMA(1,1)-GARCH(2,2).

Dari hasil pemodelan, diperoleh bahwa model GARCH(m,s) terbaik adalah model ARMA(1,1)-GARCH(2,2) dengan parameter model yang signifikan, memenuhi asumsi homoskedastisitas residual, dan memiliki nilai AIC yang paling rendah, yaitu -3,3139. Persamaan model ARMA(1,1)-GARCH(2,2) dapat diperoleh berdasarkan persamaan umum model GARCH(m,s) pada persamaan (11).

Mean model ARMA (1,1) : $R_t = e_t - 0,775579R_{t-1} - 0,734225e_{t-1}$

Varian Model GARCH(2,2) :

$$\sigma_t^2 = 0,000163 + 0,057729 \varepsilon_{t-1}^2 + 0,259587 \varepsilon_{t-2}^2 + 0,136179 \sigma_{t-1}^2 + 0,530631 \sigma_{t-2}^2$$

Pengujian sign bias dilakukan sebagai tahap untuk melihat ada tidaknya efek asimetris dalam model ARMA(1,1)-GARCH(2,2), sehingga apabila terdapat efek asimetris pemodelan harus menggunakan model GARCH asimetris.

Tabel 2. Hasil Pengujian Sign Bias pada Model ARMA(1,1)-GARCH(2,2)

Parameter	t-value	p-value	Keputusan
<i>Sign Bias</i>	2,7940	0,005299	H_0 ditolak
<i>Negative Sign Bias</i>	0,7123	0,476416	H_0 gagal ditolak
<i>Positive Sign Bias</i>	1,0276	0,304350	H_0 gagal ditolak
Parameter	LM	p-value	Keputusan

Pada taraf signifikansi 5%, parameter *sign bias* dan *join effect* menolak H₀ karena nilai p-value < α maka residual model ARMA(1,1)-GARCH(2,2) memiliki efek asimetris sehingga harus dimodelkan dengan menggunakan model GARCH asimetris yang terdiri dari model EGARCH(m,s), TGARCH(m,s), dan APARCH(m,s).

Berdasarkan hasil pemodelan GARCH asimetris, diperoleh model terbaik yaitu model TGARCH (1,1) dengan nilai AIC yang paling minimum sebesar -3,2906. Model TGARCH (1,1) memiliki koefisien parameter model yang signifikan dan memenuhi syarat kecukupan model dimana $a_0 > 0$, $a_i \geq 0$, $\beta_j \geq 0$ dengan $\gamma_i > 0$. Nilai *leverage effect* yang bernilai positif ($\gamma_i > 0$) menandakan bahwa *bad news* akan memiliki efek yang kuat dibandingkan dengan *good news* begitu pula sebaliknya. Model TGARCH(1,1) juga memenuhi asumsi homoskedastisitas residual sebagai syarat kecukupan model. Model TGARCH(1,1) memiliki parameter model yang signifikan sehingga semua parameter dimasukkan ke dalam pemodelan. Persamaan model TGARCH(1,1) dengan model rata-rata yang terbentuk adalah: *Mean Model* - ARMA(1,1):

$$R_t = \phi_1 R_{t-1} - \theta_1 e_{t-1} + e_t$$

$$R_t = e_t - 0,684209R_{t-1} - 0,601612e_{t-1}$$

Varian Model - TGARCH(1,1):

$$\sigma_t^2 = a_0 + \sum_{i=1}^1 a_i \varepsilon_{t-i}^2 + \sum_{i=1}^1 \gamma_i N_{t-i} \varepsilon_{t-i}^2 + \sum_{j=1}^1 \beta_j \sigma_{t-j}^2$$

$$\sigma_t^2 = a_0 + a_1 \varepsilon_{t-1}^2 + \gamma_1 N_{t-1} \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

$$\sigma_t^2 = 0,001709 + 0,206861 \varepsilon_{t-1}^2 + 0,827725 \varepsilon_{t-1}^2 + 0,182119 \sigma_{t-1}^2$$

Pada pemodelan EGARCH(m,s), koefisien parameter model γ_k atau parameter *leverage effect* tidak memenuhi syarat kecukupan koefisien parameter model dimana $\gamma_k < 0$, sehingga model EGARCH(m,s) tidak dapat digunakan untuk pemodelan. Sedangkan, pada model APARCH(m,s) parameter *leverage effect* (γ_i) dari model yang terbentuk tidak ada yang signifikan terhadap model sehingga model APARCH (m,s) juga tidak dapat digunakan dalam memodelkan volatilitas *return* BNB-USD yang memiliki efek asimetris.

Pada penelitian ini akan digunakan data *out sample* berupa data volatilitas harian *return* BNB-USD selama 7 hari kedepan mulai dari tanggal 05 Februari 2023 hingga 11 Februari 2023 yang diperoleh dengan menggunakan *realized volatility* pada persamaan (2). Hasil peramalan *return* dan peramalan volatilitas harian *return* BNB-USD dengan model TGARCH(1,1) selama 7 periode ke depan dapat dilihat di Tabel 3.

Tabel 3. Perbandingan Hasil Peramalan Model GARCH Asimetris dengan Data Asli

Periode Peramalan	Data Volatilitas Harian	Expected Return Harian	Peramalan Volatilitas TGARCH(1,1)	Peramalan Return TGARCH(1,1)
05/02/2023	0,02811	-0,00031	0,02864	0,00092
06/02/2023	0,02471	0,00012	0,03014	-0,00063
07/02/2023	0,02558	0,00004	0,03163	0,00043
08/02/2023	0,02543	0,00003	0,03311	-0,00029
09/02/2023	0,02611	-0,00082	0,03458	0,00020

10/02/2023	0,03206	-0,00077	0,03604	-0,00014
11/02/2023	0,02827	0,00023	0,03749	0,00009
RMSE			0,00653	
MAE			0,00591	
SMAPE			19,53%	

Berdasarkan hasil evaluasi kinerja model yang diperoleh, dapat disimpulkan bahwa peramalan volatilitas *return* dengan model TGARCH(1,1) memiliki nilai RMSE dan MAE yang kecil yaitu 0,00653 dan 0,00591. Pada output akurasi peramalan model TGARCH(1,1) diperoleh nilai SMAPE sebesar 19,53%. Nilai SMAPE yang berada di antara rentang kurang dari sama dengan 10% sampai dengan kurang dari 20% menyatakan bahwa model TGARCH(1,1) memiliki kemampuan peramalan yang baik untuk meramalkan volatilitas harian *return* BNB-USD selama 7 hari ke depan.

5. KESIMPULAN

Pada peramalan volatilitas *return* harian BNB-USD sebagai salah satu mata uang virtual *cryptocurrency*, model GARCH asimetris TGARCH(1,1) menjadi model yang paling cocok dalam meramalkan volatilitas harian *return* BNB-USD dengan persamaan model:

Mean Model – ARMA (1,1) : $R_t = e_t - 0,684209R_{t-1} - 0,601612e_{t-1}$

Varian Model TGARCH(1,1):

$$\sigma_t^2 = 0,001709 + 0,206861\varepsilon_{t-1}^2 + 0,827725\varepsilon_{t-1}^2 + 0,182119\sigma_{t-1}^2$$

Tingkat akurasi peramalan dengan menggunakan nilai SMAPE diperoleh nilai sebesar 19,53% yang menyatakan bahwa model TGARCH (1,1) memiliki kemampuan peramalan yang baik untuk meramalkan volatilitas harian *return* BNB-USD selama 7 hari selanjutnya.

DAFTAR PUSTAKA

- Ahmad, W. M. A.W., Naing, N. N., dan Halim, N. A. 2008. *An Application of Box Cox Transformation to Biostatistics Experiment Data*. Journal of Bioscience Vol. 1 No. 19: Hal.137-145.
- Ampountolas, A. 2022. *Cryptocurrencies Intraday High-Frequency Volatility Spillover Effects Using Univariate and Multivariate GARCH Models*. International Journal of Financial Studies Vol. 10 No.51: Hal.1-22.
- Andersen, T. G., Bollerslev, T., Diebold, F. X., dan Labys, P. 2001. *The Distribution of Realized Stock Return Volatility*. Journal of Financial Economics No. 61: Hal. 43–76.
- Bergsli, L.O., Lind, A. F., Molnar, P., dan Polasik, M. 2022. *Forecasting Volatility of Bitcoin*. Research in International Business and Finance No. 59: Hal.1-30.
- Bollerslev, T. 1986. *Generalized Autoregressiv Conditional Heteroskedasticity*. Journal of Econometrics Vol. 31: Hal.307–327.
- Box, G. E., Cox, D. R. 1964. *An Analysis of Transformation*. Journal of the Royal Statistical Society Series B (Methodological) Vol.2, No.26: Hal.211–252.
- Brooks, C. 2008. *Introductory Econometrics for Finance*. New York: Cambridge University Press.
- Engle, R. 1982. *Autoregressive Conditional Heteros-kedasticity with Estimates of The Variance of UK Inflation*. Econometrica Vol. 50, No. 4: Hal.987-1008
- Francq, C., Zakoian, J. M. 2019. *GARCH Model Structure, Statistical Inference and Financial Application*. Prancis: A John Wiley and Sons, Ltd.
- Hartono, S., Budiarsih, R. 2022. *Potensi Kesuksesan Penerapan Pajak Penghasilan Terhadap Transaksi Aset Kripto di Indonesia*. Jurnal Pajak dan Keuangan Negara Vol.04 No. 1: Hal. 132-146.

- Hyndman, R. J., Khandakar, Y. 2008. *Automatic Time Series Forecasting: The forecast Package for R*. Journal of Statistical Software Vol. 27, No.3: Hal.1–22.
- Khodir, R. 2020. *Analisis Volatilitas Cryptocurrency untuk Estimasi Value at Risk Menggunakan Model GARCH*. Medan. Penerbit Universitas Sumatera Utara Medan.
- Lee, L. 2004. *Asymptotic Distributions of Quasi-Maximum Likelihood Estimators for Spatial Autoregressive Models*. Econometrica Vol. 72, No. 6: Hal.1899-1925.
- Rosadi, D. 2011. *Ekonometrika & Analisis Runtun Waktu Terapan dengan Eviews*. Yogyakarta: Andi Offset.
- Sari, L.K., Achsani, N. A., dan Sartono, B. 2017. *Pemodelan Volatilitas Return Saham : Studi Kasus Pasar Saham Asia*. Jurnal Ekonomi dan Pembangunan Indonesia Vol. 18, No. 1: Hal.35-52.
- Sukartini, M. 2022. *Penerapan Model Generalized Autoregressive Conditional Heteroscedasticity (GARCH) dalam Peramalan Indeks Saham Syariah di Negara Asia*. Yogyakarta. Penerbit Universitas Islam Indonesia.
- Tsay, R.S. 2005. *Analysis of Financial Time Series*. Canada : John Wiley and Sons, inc.
- Wei, W.W.S. 2006. *Time Series Analysis, Univariate and Multivariate Methods*. Canada: Addison Wesley Publishing Company.
- Wibowo, N.M. 2016. *Pemodelan Return Saham Perbankan Menggunakan Exponential Generalized Autoregressive Condition Heteroscedasticity (EGARCH)*. Jurnal Gaussian Vol.6 No.1: Hal.91-99.
- Zivot, E. 2015. *Modeling Financial Time Series with R*. New York: Springer-Verlag.