

BAB I PENDAHULUAN

1.1. Latar Belakang

Perkembangan teknologi dan digitalisasi seperti hadirnya jaringan 5G, *cloud computing*, sampai pada perkembangan *artificial intelligence (AI)* dan *blockchain* telah membawa perkembangan aset investasi ke arah yang lebih modern. Perkembangan ini ditandai dengan hadirnya jenis aset investasi baru yang menawarkan potensi keuntungan yang signifikan, yaitu aset *cryptocurrency* (Huda dkk., 2023). *Cryptocurrency* merupakan bentuk aset digital yang terdesentralisasi dan berbasis teknologi *blockchain*, yang memungkinkan transaksi secara *peer-to-peer* tanpa melibatkan lembaga keuangan sentral (Shahzad dkk., 2024). Bitcoin adalah salah satu contoh populer dari *cryptocurrency* yang merupakan mata uang digital pertama yang diperkenalkan oleh seseorang atau kelompok yang menggunakan nama samaran Satoshi Nakamoto pada tahun 2008 (Nuryanto & Pramudianto, 2021). Nakamoto (2008) mendefinisikan koin elektronik sebagai sebuah tanda tangan digital yang berantai, di mana setiap transaksi tercatat dalam *blockchain* dengan jaringan yang membentuk *timestamp* (catatan waktu), karena transaksi tercatat setiap waktu mengakibatkan jaringan membentuk rantai panjang yang sehingga sulit untuk diretas.

Adopsi Bitcoin sebagai bentuk pembayaran di berbagai sektor terus mengalami perkembangan menjadikan Bitcoin sering dianggap sebagai *store of value* baik sebagai alat pembayaran maupun sebagai instrumen spekulatif. (Budiartomo & Setiyono, 2023). Data menunjukkan bahwa harga Bitcoin memiliki karakteristik yang fluktuatif. Misalnya, pada Januari 2021, harga Bitcoin mencapai harga sekitar \$29.000, lalu pada April 2021, harga Bitcoin melonjak hingga lebih dari \$63.000, sebelum akhirnya mengalami penurunan signifikan menjadi \$32.000 pada pertengahan tahun 2021 (CoinMarketCap, 2024). Fluktuasi harga yang ekstrem ini menunjukkan perlunya peramalan yang akurat untuk membantu pelaku pasar dalam mengambil keputusan investasi yang lebih baik. Dalam konteks ini, model *Autoregressive Integrated Moving Average (ARIMA)* menjadi salah satu metode yang relevan dan umum untuk melakukan peramalan. Model ini mampu menangkap pola data deret waktu dan memberikan hasil peramalan yang mendekati data aktual (Listiani & Mahkya, 2022). Meskipun model ARIMA efektif dalam memprediksi pola tren dan musiman pada data deret waktu, model ini memiliki keterbatasan dalam menangkap fenomena heteroskedastisitas dan efek asimetris yang melekat pada volatilitas



dengan volatilitas harga yang tinggi, menyebabkan fluktuasi harga dalam waktu singkat. Artinya, Ketika terjadi perubahan harga yang signifikan, volatilitas cenderung meningkat lebih besar dibandingkan dengan perubahan harga yang positif (kenaikan) sehingga memiliki kondisi yang tidak stabil. Volatilitas yang tinggi menyebabkan variabilitas *return* tidak dapat diprediksi dalam waktu (*heteroskedastisitas*), suatu kondisi yang tidak dapat

diakomodasi oleh model ARIMA (Putra & Robiyanto, 2021). Untuk mengatasi kelemahan ARIMA, *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) diperkenalkan guna memodelkan volatilitas dengan mempertimbangkan varians residual masa lalu dan varians *return* sebelumnya, sehingga mampu menangkap fenomena *heteroskedastisitas*, GARCH mampu memberikan estimasi terhadap fluktuasi harga dan risiko dalam pasar keuangan khususnya *cryptocurrency* (Akbar dkk., 2023). Namun, salah satu keterbatasan utama dari model GARCH adalah ketidakmampuannya untuk menangkap ketidak simetrisan yang terjadi dalam *cryptocurrency*.

Asymmetric Power Autoregressive Conditional Heteroskedasticity (APARCH) dikembangkan untuk mengatasi kekurangan GARCH. APARCH berperan dengan memperkenalkan parameter daya dan asimetri yang fleksibel, memungkinkan model menyesuaikan diri terhadap pola volatilitas yang kompleks sekaligus mengukur dampak asimetris dari guncangan harga dengan memperhitungkan efek *leverage*, sehingga memberikan gambaran yang lebih komprehensif tentang perilaku volatilitas *cryptocurrency* (Sidadolog dkk., 2020). Beberapa penelitian sebelumnya telah menerapkan metode APARCH dalam menganalisis volatilitas dari suatu aset. Irene (2020) membandingkan kinerja metode *Asymmetric Power Autoregressive Conditional Heteroscedasticity* (APARCH), *Exponential Generalized Autoregressive Conditional Heteroskedasticity* (EGARCH), dan *Threshold Generalized Autoregressive Conditional Heteroskedasticity* (TGARCH), dalam meramalkan harga emas dunia dan menemukan nilai *Mean Absolute Percentage Error* (MAPE) berturut-turut sebesar 5,68%, 5,23%, 4,66%. Sidadolog (2020) Meramalkan volatilitas return saham menggunakan metode APARCH, dan mendapatkan hasil APARCH (1,2) sebagai model terbaik dengan nilai *Akaike Information Criterion* (AIC) sebesar 2,88. Curto (2022) mengimplementasikan model APARCH (1,1) dalam melihat dampak covid-19 terhadap volatilitas indeks sektor S&P 500.

Berdasarkan pembahasan sebelumnya mengenai pentingnya memahami volatilitas suatu aset, khususnya *cryptocurrency* Bitcoin sebagai salah satu pilihan aset investasi, terlihat bahwa Bitcoin menawarkan potensi keuntungan yang signifikan, namun sering kali menghadapi lonjakan dan penurunan harga yang tajam dalam waktu singkat, menjadikan *cryptocurrency* lebih berisiko. Sehingga, analisis volatilitas harga Bitcoin menggunakan metode GARCH khususnya metode APARCH sangat relevan untuk memahami fluktuasi harga yang ekstrem dan untuk memberikan panduan yang lebih akurat dalam pengambilan keputusan investasi di pasar *cryptocurrency* yang dinamis ini. Oleh karena itu, Penelitian ini bertujuan untuk



APARCH sebagai variasi dari GARCH, yang secara efektif volatilitas dan heteroskedastisitas dalam data. Penelitian ini arya berjudul **“Analisis Volatilitas Harga *Cryptocurrency* an Metode *Asymmetric Power Autoregressive Conditional***

1.2. Batasan Masalah

Penelitian ini terbatas pada beberapa Batasan masalah yakni sebagai berikut:

1. Data yang digunakan dalam penelitian ini merupakan data univariat harga Bitcoin harian dengan total 731 data mulai dari 1 Januari 2023 sampai 31 Desember 2024.
2. Metode estimasi parameter yang digunakan adalah *Maximum Likelihood Estimation* (MLE)

1.3. Tujuan dan Manfaat Penelitian

Tujuan dari penelitian ini adalah :

1. Memperoleh estimasi parameter model *Asymmetric Power Autoregressive Conditional Heteroskedasticity*.
2. Memperoleh hasil prediksi model *Asymmetric Power Autoregressive Conditional Heteroskedasticity* dalam menangkap volatilitas Bitcoin periode 08 Agustus 2024 – 31 Desember 2024.

Manfaat yang diharapkan dari penelitian ini adalah :

1. Memberikan informasi mengenai analisis volatilitas aset investasi bitcoin menggunakan metode *Asymmetric Power Autoregressive Conditional Heteroskedasticity*.
2. Sebagai inspirasi bagi pembaca dalam mengembangkan metode *Generalized Autoregressive Conditional Heteroskedasticity* yang mampu menangkap heteroskedastisitas dan pola fluktuasi volatilitas suatu data.

1.4. Landasan Teori

1.4.1. Data Deret Waktu

Data deret waktu merupakan serangkaian data yang diamati dan terjadi berdasarkan indeks waktu yang tersusun secara berurutan dalam interval waktu. Sedangkan, Analisis *Time series* (analisis deret waktu) merupakan sebuah metode penting dalam statistik, yang digunakan untuk menganalisis dan mempelajari karakteristik yang meliputi adanya pola trend, musiman, siklus, dan noise, yang digunakan untuk membantu memprediksi nilai di masa mendatang (Susanti & Adji, 2020).

1.4.2. Log Return

Log return atau *logarithmic return* adalah salah satu metode yang umum digunakan dalam analisis data keuangan, terutama untuk menganalisis perubahan harga instrumen keuangan dalam periode waktu yang panjang (Utami dkk., 2021). *Log return* mengukur perubahan relatif antara harga suatu aset pada dua titik waktu yang berbeda dan dihitung menggunakan fungsi logaritma dari rasio harga pada dua titik waktu. Secara umum *log return* dapat didefinisikan dalam Persamaan

$$Z_t = \ln \left(\frac{P_t}{P_{t-1}} \right) \quad (1)$$



dengan :

Z_t : *Log return* periode t

P_t : Harga penutupan pada periode t

P_{t-1} : Harga penutupan pada periode sebelumnya

1.4.3. Stasioneritas

Stasioneritas adalah salah satu konsep fundamental dalam analisis data *time series*. Sebuah data *time series* dikatakan stasioner jika statistiknya tidak berubah seiring waktu, yang berarti nilai rata-rata, varians, dan kovariansnya bersifat tetap di sepanjang waktu. Stasioneritas menjadi sangat penting dalam analisis *time series* karena banyak model analisis tidak akan valid apabila data yang digunakan tidak stasioner (Aktivani, 2020). Salah satu uji yang digunakan dalam mengecek apakah data bersifat stasioner atau tidak adalah dengan menggunakan uji ADF (*Augmented Dickey Fuller*), ADF dapat membantu dalam mengatasi kasus data yang memiliki ketergantungan autokorelasi tinggi dengan mengasumsikan adanya tren deterministik pada data (Widiyanto & Mayasari, 2023). Statistik uji yang digunakan dalam uji stasioner ditunjukkan dalam Persamaan (2) berikut.

$$ADF = \frac{\hat{\beta}}{se(\hat{\beta})} \quad (2)$$

dengan :

$\hat{\beta}$: Estimasi *least square* dari β (Koefisien parameter model)

$se(\hat{\beta})$: standar *error* dari $\hat{\beta}$

Hipotesis yang digunakan dalam uji ADF adalah

H_0 : $\beta = 0$ (Terdapat akar unit sehingga data tidak stasioner)

H_1 : $\beta < 0$ (Tidak terdapat akar unit sehingga data stasioner)

Kriteria pengujian dalam uji ADF adalah jika $ADF \leq t_{(n-1, \alpha)}$ atau $p - value < \alpha$ maka H_0 ditolak.

1.4.4. Autocorrelation Function dan Partial Autocorrelation Function

1. Autocorrelation Function

Autocorrelation function (ACF) digunakan untuk mengukur hubungan antara nilai-nilai yang terdapat dalam suatu deret waktu, di mana ACF akan menunjukkan korelasi antara pengamatan pada waktu Z_t dengan pengamatan pada waktu Z_{t+k} (*lag k*) dalam analisis deret waktu (Fitriani, 2021). Dengan korelasi pada *lag k*, untuk Z_t stasioner maka terdapat nilai rata-rata yang ditunjukkan pada Persamaan (3) berikut.

$$E(Z_t) = \mu \quad (3)$$

atakan pada Persamaan (4) berikut.

$$var(Z_t) = E(Z_t - \mu)^2 = \sigma^2 \quad (4)$$

Z_t dan Z_{t+k} dinyatakan pada Persamaan (5) berikut.

$$cov(Z_t, Z_{t+k}) = [(Z_t - \mu)(Z_{t+k} - \mu)] = \gamma_k \quad (5)$$



Korelasi antara Z_t dan Z_{t+k} , dinyatakan pada Persamaan (6) berikut.

$$\begin{aligned}
 \text{corr}(Z_t, Z_{t+k}) &= \frac{\text{cov}(Z_t, Z_{t+k})}{\sqrt{\text{var}(Z_t)}\sqrt{\text{var}(Z_{t+k})}} \\
 &= \frac{\text{cov}(Z_t, Z_{t+k})}{\text{var}(Z_t)} \\
 \text{corr}(Z_t, Z_{t+k}) &= \frac{E[(Z_t - \mu)(Z_{t+k} - \mu)]}{E(Z_t - \mu)^2} \\
 &= \frac{E(Z_t - \mu) E(Z_{t+k} - \mu)}{E(Z_t - \mu)^2} \\
 &= \frac{\sum_{t=1}^n (Z_t - \mu) \sum_{t=1}^n (Z_{t+k} - \mu)}{\sum_{t=1}^n (Z_t - \mu)^2} \quad (6)
 \end{aligned}$$

Diagram fungsi autokorelasi juga dapat digunakan sebagai alat untuk mengidentifikasi kestasioneran dalam data. Jika diagram ACF menunjukkan cenderung turun lambat atau turun secara linier, maka dapat disimpulkan data belum stasioner dalam rata-rata (Yuniarti, 2012).

2. Partial Autocorrelation Function

Partial Autocorrelation Function (PACF) memberikan informasi tentang seberapa besar hubungan langsung antara pengamatan saat ini dan pengamatan sebelumnya setelah mempertimbangkan efek dari pengamatan lain. PACF didefinisikan sebagai korelasi antara Z_t dan Z_{t-k} setelah menghilangkan pengaruh dari variabel $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$ (Parwita & Dewi, 2022). Secara matematis PACF dapat dinyatakan dalam Persamaan (7) berikut.

$$\phi_{kk} = \text{corr}(Z_t, Z_{t+k} \mid Z_{t+1}, Z_{t-2}, \dots, Z_{t+k-1}) \quad (7)$$

ϕ_{kk} adalah koefisien autokorelasi parsial pada lag ke- k . Nilai PACF berkisar antara -1 hingga +1, nilai mendekati +1 menunjukkan hubungan positif yang kuat, sedangkan nilai mendekati -1 menunjukkan hubungan negatif yang kuat. Nilai ϕ_{kk} dapat ditentukan dengan menggunakan persamaan Yule Walker yang ditulis dalam Persamaan (8) berikut.

$$\rho_i = \phi_{k1}\rho_{j-1} + \dots + \phi_{kk}\rho_{j-k}, \quad j = 1, 2, \dots, k-1 \quad (8)$$



tahun 1960 telah memperkenalkan metode yang lebih efisien dari persamaan Yule Walker (Aswi & Sukarna, 2006). Persamaan ini metode yang diperkenalkan oleh Durbin (1960).

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{kj}} \quad (9)$$

$-\phi_{kk}\phi_{k-1,k-j}$, untuk $j = 1, 2, \dots, k-1$

1.4.5. Model Autoregressive Integrated Moving Average

Autoregressive Integrated Moving Average (ARIMA) juga dikenal sebagai metode *Box-Jenkins* merupakan model yang menggambarkan data deret waktu yang stasioner. ARIMA terdiri dari tiga komponen yang meliputi *Autoregressive* (AR), *Integrated* (I), dan *Moving Average* (MA) (Nurmayanti dkk., 2023).

Model AR orde p menyatakan pengamatan pada periode t yang berhubungan linear dengan pengamatan waktu sebelumnya, di mana model AR dinyatakan dalam Persamaan (10) berikut.

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (10)$$

Model MA orde q menggambarkan hubungan antara pengamatan pada periode t dengan kesalahan yang terjadi pada pengamatan waktu sebelumnya, di mana model MA dinyatakan dalam Persamaan (11) berikut.

$$Z_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (11)$$

Integrated atau *differencing* dilakukan sebanyak d kali, untuk menghilangkan tren data agar data menjadi stasioner. Sehingga bentuk umum model ARIMA (p, d, q) dinyatakan dalam Persamaan (12) berikut (Wulandari & Gernowo, 2019).

$$\phi_p(B)(1-B)^d Z_t = \mu + \theta_q(B)\varepsilon_t \quad (12)$$

dengan :

Z_t : Nilai pengamatan pada waktu t .

μ : Konstanta.

B : Operator *backshift*.

d : Orde differencing yang diperlukan untuk mencapai stasioneritas.

$\phi_p(B)$: Polinomial *autoregressive*, yang dinyatakan.

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

$\theta_q(B)$: Polinomial *moving average*, yang dinyatakan.

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

ε_t : Nilai error pada waktu t

p : Orde AR

q : Orde MA

1.4.6. Uji Signifikansi Parameter

Uji signifikansi parameter dilakukan untuk menentukan kelayakan suatu parameter dalam model ARIMA (Rahmawati dkk., 2024) Menurut Wei uji signifikansi parameter dapat dilakukan dengan cara berikut.



akan

· θ tidak signifikan dalam model)

· θ signifikan dalam model)

Statistik uji:

$$t_{hitung} = \frac{\hat{\theta}}{SE(\hat{\theta})} \quad (13)$$

dengan :

$\hat{\theta}$: nilai estimasi parameter

SE : *standard error*

Kriteria uji :

Tolak H_0 Jika $|t_{hitung}| > t_{\frac{\alpha}{2}}$ di mana α adalah taraf signifikansi atau

Tolak H_0 Jika $p - value < \alpha$

1.4.7. Uji White Noise

Asumsi *white noise* mengartikan bahwa residual tidak memiliki korelasi antara satu lag dengan lag lainnya (Lailiyah & Manuwarawati, 2018). Menurut Wei (2006) uji *white noise* dapat dilakukan dengan cara berikut.

Hipotesis yang digunakan

$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$ (residual telah memenuhi *white noise*)

H_1 : minimal ada satu $\rho_k \neq 0 ; k = 1, 2, \dots, K$ (residual tidak memenuhi *white noise*)

Statistik uji:

$$w = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)} ; n > K \quad (14)$$

dengan :

K : lag maksimum

n : jumlah data pengamatan

$\hat{\rho}_k^2$: autokorelasi residual pada lag ke- k

Kriteria uji :

Jika signifikansi α diterapkan maka, tolak H_0 apabila $Q > \chi_{\alpha; K-p-q}^2$ atau

Tolak H_0 jika $p - value < \alpha$

1.4.8. Uji Lagrange-Multiplier

Uji *lagrange multiplier* digunakan untuk mengecek adanya efek ARCH dalam data. Model ARCH dan GARCH digunakan apabila terdapat varian yang tidak konstan dalam model (*heteroscedasticity*) (Fitriani, 2021). Menurut Tsay (2005) untuk melihat adanya efek ARCH menggunakan uji *lagrange multiplier* dapat dilakukan dengan cara berikut.



akan

$\alpha_k = 0$ (tidak terdapat efek ARCH dalam residual)

$\alpha_k \neq 0 ; k = 1, 2, \dots, k$ (terdapat efek ARCH dalam residual)

$$LM = nR^2 \quad (15)$$

dengan :

n : jumlah observasi

R^2 : koefisien determinasi dari regresi residual, yang dinyatakan dengan

$$R^2 = \frac{\sum_{i=1}^n (z_i - \hat{z}_i)^2}{\sum_{i=1}^n (z_i - \bar{z})^2}$$

Kriteria uji :

Jika signifikansi α diterapkan maka, tolak H_0 apabila $LM > \chi^2_{\alpha/2, k}$ atau

Tolak H_0 jika $p - value < \alpha$

1.4.9. Uji Efek Asimetris

Uji efek asimetris dilakukan guna menentukan apakah terdapat perbedaan signifikan antara dampak guncangan positif dan guncangan negatif (Sidadolog dkk., 2020). Menurut Said (2016) untuk melihat kesimetrisan dalam model dapat menggunakan uji *sign bias*. Uji *Sign Bias* diperkenalkan oleh Engle (1993) untuk mendeteksi adanya bias asimetris dalam data keuangan. Uji ini menggunakan residual kuadrat dari model volatilitas sebagai *proxy* untuk volatilitas dan meregresikannya terhadap variabel *dummy* yang merepresentasikan tanda residual serta ukuran *shock*.

Hipotesis yang digunakan

H_0 : Tidak ada perbedaan signifikan antara efek *shock* negatif dan positif terhadap volatilitas (residual bersifat simetris)

H_1 : Ada perbedaan signifikan antara efek *shock* negatif dan positif terhadap volatilitas. (residual bersifat asimetris)

Model regresi *sign bias* dituliskan dalam Persamaan (16) berikut.

$$\varepsilon_t^2 = \alpha + \beta_1 D_t^- + \beta_2 S_t^+ + \beta_3 S_t^- \quad (16)$$

dengan :

ε_t^2 : kuadrat residual dari residual standar model

D_t^- : variabel *dummy* untuk *shock* negatif

S_t^+ : *size shock positif* (berisi nilai residual standar positif)

S_t^- : *size shock negatif* (berisi nilai absolut standar negative)

Kriteria uji:

Jika signifikansi α diterapkan maka, tolak H_0 jika $p - value < \alpha$ atau

Tolak H_0 apabila $F_{hitung} > F_{tabel}$, dengan

$$F_{hitung} = \frac{\sum_{i=1}^n (\hat{\varepsilon}_i^2 - \omega)^2}{\sum_{i=1}^n \varepsilon_i^2}$$



egressive Conditional Heteroskedasticity

e *Conditional Heteroskedasticity* (ARCH) merupakan model oleh Engle (1982). Model ARCH dapat digunakan untuk *error* yang tidak konstan dalam sebuah data deret waktu atau Menurut Wei, (2006) model ARCH (p) dapat dituliskan pada kut.

$$\begin{aligned}\sigma_t^2 &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_i \varepsilon_{t-i}^2 \\ &= \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2\end{aligned}\quad (17)$$

dengan :

- σ_t^2 : variansi *residual* pada waktu t
- α_0 : komponen konstanta
- α_i : parameter ke- i dari ARCH
- ε_{t-i}^2 : *residual* kuadrat pada waktu $(t - i)$

Wei (2006) menyatakan bahwa, model ARCH mempertimbangkan variansi kondisional dari proses *error* tidak hanya terkait dengan kuadrat *error* periode sebelumnya tetapi juga dengan variansi kondisional periode sebelumnya. Sehingga diperoleh proses *error* pada Persamaan (18) berikut (Masniyah, 2020).

$$\varepsilon_t = \sigma_t w_t \quad (18)$$

dengan :

- ε_t : *error* untuk semua t
- σ_t : standar deviasi *error* untuk semua t
- w_t : variabel acak bersifat *white noise* untuk semua t

1.4.11. Model Generalized Autoregressive Conditional Heteroskedasticity

Model *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) merupakan model yang dikembangkan oleh Bollerslev pada tahun 1986 berdasarkan model ARCH yang pertama kali diperkenalkan oleh Engle, (1982). Model GARCH dibangun untuk menghindari orde yang terlalu tinggi pada model ARCH. Menurut Tsay (2005) model umum GARCH dapat dinyatakan dalam Persamaan (19) berikut.

$$\begin{aligned}\sigma_t^2 &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_i \varepsilon_{t-i}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_j \sigma_{t-j}^2 \\ &= \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2\end{aligned}\quad (19)$$

dengan :

- σ_t^2 : variansi *residual* pada waktu t
- α_0 : komponen konstanta
- α_i : parameter ke- i dari ARCH
- ε_{t-i}^2 : *residual* kuadrat pada waktu $(t - i)$



- β_j : parameter ke- j dari GARCH
- σ_{t-j}^2 : *residual* kuadrat pada waktu $(t - j)$

Power Autoregressive Conditional Heteroscedasticity

Power Autoregressive Conditional Heteroscedasticity (APARCH) dikembangkan oleh Ding, Granger, dan Engle pada tahun 1993. Model

APARCH merupakan pengembangan dari model GARCH yang dirancang untuk menangkap efek asimetris dalam volatilitas pada data keuangan, dengan kata lain APARCH dirancang untuk menangkap perbedaan dampak guncangan positif dan negatif terhadap volatilitas (Sidadolog dkk., 2020). Menurut Curto (2022) bentuk umum model APARCH (p, q) ditulis dalam persamaan berikut.

$$\sigma_t^\delta = \omega + \sum_{i=1}^p \alpha_i (|\varepsilon_{t-i}| - \gamma \varepsilon_{t-i})^\delta + \sum_{j=1}^q \beta_j \sigma_{t-1}^\delta \quad (20)$$

dengan :

- ω : konstanta
- α_i : parameter ARCH, untuk $i = 1, 2, \dots, p$ dan ≥ 0
- β_j : parameter GARCH, untuk $j = 1, 2, \dots, q$ dan ≥ 0
- ε_{t-1} : nilai error pada $t - 1$
- p : orde ARCH
- q : orde GARCH
- γ : konstanta asimetris (*leverage effect*)
- δ : parameter APARCH

δ merupakan parameter yang harus memiliki nilai bebas, jika tidak maka akan terdapat beberapa kasus khusus yang akan membentuk model GARCH lain baik model asimetris maupun model simetris (Pandia dkk., 2019). Menurut Ding (1993) apabila parameter δ terikat maka akan menghasilkan model berikut.

1. Model ARCH Ketika $\delta = 2, \beta_j = 0$ ($j = 1, 2, \dots, q$), $\gamma_i = 0$ ($i = 1, 2, \dots, i$)
2. Model GARCH Ketika $\delta = 2, \gamma_i = 0$ ($i = 1, 2, \dots, i$)
3. Model *Glosten-Jagannathan-Runkle*-GARCH Ketika $\delta = 2$
4. Model *Threshold*-ARCH Ketika $\delta = 1$

1.4.13. Estimasi Parameter

Metode *Maximum Likelihood Estimation* (MLE) merupakan teknik statistik yang digunakan untuk memperkirakan parameter dari suatu model dengan memaksimalkan fungsi *likelihood*. Fungsi ini akan mengukur seberapa baik model dalam menjelaskan data yang sedang diamati (Purba, 2019). Misalkan terdapat $y_1, y_2, \dots, y_n$ dari suatu populasi yang memiliki fungsi probabilitas ($y; p$); $p \in \Omega$, di mana p adalah parameter yang tidak diketahui dan Ω adalah ruang parameter. Karena $y_1, y_2, \dots, y_n$ adalah sampel acak maka fkp Bersama dari $y_1, y_2, \dots, y_n$ adalah.

$$f(y_1, y_2, \dots, y_n; \theta) = f(y_1; \theta) f(y_2; \theta) \dots f(y_n; \theta) \quad (21)$$

Menurut Hogg (1995), fungsi *likelihood* didefinisikan sebagai fkp bersama, *od* dinotasikan sebagai $L(\theta; y_1, y_2, \dots, y_n) = L(\theta; \sigma^2)$ maka.

$$\begin{aligned} L(\theta; \sigma^2) &= f(y_1, y_2, \dots, y_n; \theta) \\ &= f(y_1; \theta) f(y_2; \theta) \dots f(y_n; \theta) \\ &= \prod_{i=1}^n f(y_i; \theta) \end{aligned} \quad (22)$$



Untuk mendapatkan fungsi *log-likelihood* dapat diambil dari fungsi *likelihood* gabungan.

$$\begin{aligned}
 L(\theta; \sigma^2) &= \ln L(y_1, y_2, \dots, y_T; \theta) \\
 &= \sum_{t=1}^T \left(-\frac{1}{2} \ln(2\pi) - \frac{1}{2} \ln(\sigma^2) - \frac{\varepsilon_t^2}{2\sigma^2} \right) \\
 &= -\frac{T}{2} \ln(2\pi) - \frac{1}{2} \sum_{t=1}^T \left(\ln(\sigma^2) + \frac{\varepsilon_t^2}{\sigma^2} \right) \quad (23)
 \end{aligned}$$

Penduga dari θ dalam metode MLE diperoleh dengan memaksimumkan fungsi $\ln L(\theta)$. Sehingga penduga dari θ dapat diperoleh dengan menemukan solusi persamaan berikut.

$$\frac{\partial l(\theta)}{\partial(\theta)} = 0 \quad (24)$$

Misalkan, model ARCH(1) memiliki persamaan sebagai berikut.

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2$$

Maka fungsi *log likelihood* untuk ARCH (1) adalah sebagai berikut.

$$\ln L = -\frac{1}{2} \ln(2\pi) - \frac{1}{2} \left(\sum_{t=1}^T \left(\ln(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2) + \frac{\varepsilon_t^2}{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} \right) \right) \quad (25)$$

Untuk memperoleh estimasi dari parameter α_0 , dilakukan deifferensiasi $\ln L$ pada Persamaan (25) terhadap α_0 . Sehingga diperoleh persamaan berikut dengan menerapkan Persamaan (24).

$$\begin{aligned}
 \frac{\partial \ln L}{\partial \alpha_0} &= -\frac{1}{2} \sum_{t=1}^T \left(\frac{1}{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} - \frac{\varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)^2} \right) \\
 0 &= -\frac{1}{2} \sum_{t=1}^T \left(\frac{1}{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} - \frac{\varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)^2} \right) \\
 &= -\frac{1}{2} \sum_{t=1}^T \frac{1}{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} = -\frac{1}{2} \sum_{t=1}^T \frac{\varepsilon}{(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)^2} \\
 \sum_{t=1}^T \frac{1}{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} &= \sum_{t=1}^T \frac{\varepsilon}{(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)^2} \quad (26)
 \end{aligned}$$



eroleh estimasi dari parameter α_1 , dilakukan deifferensiasi $\ln L$ terhadap α_1 . Sehingga diperoleh persamaan berikut dengan an (24).

$$\begin{aligned}
\frac{\partial \ln L}{\partial \alpha_1} &= -\frac{1}{2} \sum_{t=1}^T \left(\frac{1}{\varepsilon_{t-1}^2 (\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)} - \frac{\varepsilon_{t-1}^2 \varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)^2} \right) \\
0 &= -\frac{1}{2} \sum_{t=1}^T \left(\frac{1}{\varepsilon_{t-1}^2 (\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)} - \frac{\varepsilon_{t-1}^2 \varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)^2} \right) \\
&\quad - \frac{1}{2} \sum_{t=1}^T \frac{1}{\varepsilon_{t-1}^2 (\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)} = -\frac{1}{2} \sum_{t=1}^T \frac{\varepsilon_{t-1}^2 \varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)^2} \\
&\quad \sum_{t=1}^T \frac{1}{\varepsilon_{t-1}^2 (\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)} = \sum_{t=1}^T \frac{\varepsilon_{t-1}^2 \varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon_{t-1}^2)^2} \quad (27)
\end{aligned}$$

Persamaan (26) dan Persamaan (27) memperlihatkan bahwa persamaan tidak berbentuk *close form* sehingga untuk mencari taksiran parameter dalam bentuk analitik tidak dapat dilakukan, maka untuk menentukan taksiran parameternya dilakukan secara numerik (Amelia, 2015).

1.4.14. Metode Newton-Raphson

Metode Newton-Raphson merupakan salah satu metode numerik yang populer untuk mencari akar-akar dari fungsi non-linear. Metode ini dikembangkan oleh Isaac Newton dan Joseph Raphson pada tahun 1690. Metode ini berfungsi untuk menemukan solusi dari persamaan dengan menggunakan pendekatan iterasi yang cepat dan efisien (Rochmad, 2013). Menurut Nurman (2024) persamaan untuk metode Newton-Raphson dapat ditulis dengan persamaan (28) berikut.

$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)} \quad (28)$$

dengan :

x_n : parameter pada iterasi ke- n

$f(x_n)$: nilai fungsi pada x_n

$f'(x_n)$: turunan fungsi pada x_n

Proses iterasi akan terus berlanjut hingga konvergensi tercapai, yaitu perbedaan antara dua iterasi berturut-turut menjadi sangat kecil (Rochmad, 2013).

1.4.15. Pemilihan Model Terbaik

Pemilihan model merupakan proses evaluasi untuk mengetahui seberapa besar peluang model terbentuk sudah benar. Kriteria untuk menentukan model terbaik yang ialah *Akaike Information Criterion* (AIC) (Ernawati, 2023). Model arkan nilai AIC terkecil. Menurut Akaike (1974) persamaan AIC ersamaan (29) berikut.

$$AIC = 2k - 2 \ln(\hat{\theta}) \quad (29)$$



1.4.16. Akurasi Prakiraan

Akurasi prakiraan adalah ukuran seberapa dekat hasil prakiraan dengan nilai yang sebenarnya. Metrik umum yang digunakan untuk mengukur akurasi prakiraan adalah *Mean Absolute Percentage Error* (MAPE) (Winata & Hapsari, 2017). Apabila Z_t adalah data asli, $\hat{Z}_t$ adalah prakiraan, dan n adalah banyak data, maka kriteria akurasi ditunjukkan dalam persamaan (30) berikut.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100 \quad (30)$$

Kriteria MAPE dapat dilihat pada Tabel 1 berikut (Muhayani, 2019).

Tabel 1. Signifikansi MAPE

MAPE	Signifikansi
< 10 %	Kemampuan prakiraan sangat bagus
10% – 20%	Kemampuan prakiraan bagus
20% – 50%	Kemampuan prakiraan layak
> 50%	Kemampuan prakiraan tidak bagus

1.4.17. Uji Korelasi

Uji korelasi merupakan metode statistik yang digunakan untuk mengetahui keeratan hubungan antara dua atau lebih variabel yang berbeda, yang digambarkan dengan ukuran koefisien korelasi. Uji ini dapat memberikan gambaran mengenai kekuatan dan arah hubungan linear antara variabel-variabel yang diteliti (Novianti dkk., 2022). Uji korelasi dapat dihitung menggunakan persamaan berikut.

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (31)$$

1.4.18. Cryptocurrency Bitcoin

Bitcoin pertama kali diluncurkan pada tahun 2009 oleh individu atau kelompok yang dikenal dengan nama samaran Satoshi Nakamoto, merupakan cryptocurrency pertama yang menggunakan teknologi blockchain untuk memfasilitasi transaksi secara *peer-to-peer* tanpa memerlukan otoritas pusat. Berbeda dengan saham yang trasaksinya dilakukan ketika memasuki waktu bursa, transaksi cryptocurrency dapan dilakukan 24 jam bahkan diwaktu libur. Makalah Satoshi yang berjudul "*Bitcoin: A Peer-to-Peer Electronic Cash System*" menjelaskan bagaimana teknologi blockchain dapat digunakan untuk menyimpan catatan transaksi secara permanen dan tidak dapat diubah sehingga mengurangi risiko penipuan dan manipulasi data (Nakamoto,




n beroperasi melalui jaringan *node* yang saling terhubung, di memiliki salinan lengkap dari buku besar transaksi (*blockchain*). gkinkan setiap transaksi diverifikasi oleh jaringan tanpa perlu mo & Setiyono, 2023).

1.4.19. Volatilitas

Volatilitas merupakan ukuran statistik yang merepresentasikan seberapa besar perbedaan antara suatu aset selama periode tertentu. Ketidakpastian antara imbal hasil yang diperoleh akan sebanding dengan volatilitas yang dikarenakan semakin fluktuatifnya suatu aset, maka semakin cepat pula kemungkinan naik dan turunnya perubahan harga. Konsep investasi mengartikan volatilitas sebagai ukuran risiko, di mana semakin tinggi volatilitas, maka semakin besar risiko yang harus ditanggung oleh investor (Ridho, 2024).

Relative Volatility Suggests Future Market Expansion



Gambar 1. Ilustrasi Pergerakan Volatilitas
(sumber : <https://news.tokocrypto.com/>)



Optimized using
trial version
www.balesio.com

BAB II METODOLOGI PENELITIAN

2.1. Sumber Data

Data yang digunakan dalam penelitian ini adalah data univariat harga Bitcoin harian dengan total 731 jumlah observasi, mulai dari 01 Januari 2023 sampai 31 Desember 2024. Data diperoleh secara sekunder berupa data runtun waktu (*time series*) dari website www.yahooofinance.com yang diterbitkan oleh CoinMarketCap dengan satuan berupa *United States Dollar* (USD). Data kemudian dibagi menjadi 80% data *training* berjumlah 584 jumlah observasi dan 20% data *testing* berjumlah 146 jumlah observasi.

2.2. Analisis Data

Metode analisis yang digunakan dalam penelitian ini adalah *Asymmetric Power Autoregressive Conditional Heteroscedasticity*. Pengolahan data dibantu dengan perangkat lunak *R-Studio*. Adapun tahapan analisis data yang diperlukan adalah sebagai berikut.

1. Melakukan eksplorasi data awal dengan mengubah data harga penutupan harian Bitcoin ke dalam bentuk *return*. Pengubahan dilakukan menggunakan Persamaan (1).

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

2. Membagi data kedalam data *training* (01 Januari 2023 - 07 Agustus 2024) dan data *testing* (08 Agustus 2024 – 31 Desember 2024).
3. Membuat grafik dan statistik deskriptif untuk mengetahui gambaran awal dari data.
4. Melakukan pengujian stasioneritas dengan menggunakan Persamaan (2). Jika data stasioner maka dilakukan pembentukan model ARIMA. Jika data tidak stasioner maka dilakukan *differencing* kemudian dilanjutkan untuk pembentukan model ARIMA.

$$ADF = \frac{\hat{\beta}}{se(\hat{\beta})}$$

5. Menentukan model ARIMA serta mendapatkan estimasi parameter dari model. Pemilihan model didasarkan pada nilai probabilitas yang signifikan serta memiliki nilai AIC terendah dengan menggunakan Persamaan (29).



$$AIC = 2k - 2 \ln(\hat{\theta})$$

pengujian efek ARCH terhadap residual data untuk mengetahui skedastisitas dengan menggunakan Persamaan (15).

$$LM = nR^2$$

7. Menentukan model GARCH serta mendapatkan estimasi parameter dari model. Pemilihan model didasarkan pada nilai probabilitas yang signifikan serta memiliki nilai AIC terendah dengan menggunakan Persamaan (29).

$$AIC = 2k - 2 \ln(\hat{\theta})$$

8. Melakukan pengujian asimetris dari model GARCH dengan menggunakan Persamaan (16). Jika data bersifat simetris maka digunakan model GARCH, jika data bersifat asimetris maka digunakan model APARCH.

$$\varepsilon_t^2 = \alpha + \beta_1 D_t^- + \beta_2 S_t^+ + \beta_3 S_t^-$$

9. Menentukan model APARCH serta mendapatkan estimasi parameter dari model. Pemilihan model didasarkan pada nilai probabilitas yang signifikan serta memiliki nilai AIC terendah dengan menggunakan Persamaan (29).

$$AIC = 2k - 2 \ln(\hat{\theta})$$

10. Melakukan prakiraan/prediksi volatilitas data dengan menggunakan model yang diperoleh.
11. Mengukur akurasi prediksi untuk melihat seberapa dekat nilai variabel terikat berhasil diprakirakan dengan cara melihat nilai MAPE dan nilai korelasi yang diperoleh dari Persamaan (30) dan Persamaan (31).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100$$

$$Korelasi (r) = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

12. Melakukan penarikan kesimpulan berdasarkan hasil analisis yang diperoleh.

