

PENERAPAN MODEL *ASYMMETRIC POWER AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY* (APARCH) TERHADAP HARGA MINYAK MENTAH DUNIA

Ahmad Famuji^{1*}, Idhia Sriliana², Winalia Agwil³

^{1,2,3}Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Bengkulu

*e-mail : ahmadfahmuji@gmail.com

DOI: 10.14710/j.gauss.13.1.99-109

Article Info:

Received: 2024-05-20

Accepted: 2024-09-25

Available Online: 2024-09-26

Keywords:

Crude Oil; Heteroscedasticity;

Volatility; ARCH; GARCH;

APARCH

Abstract: Heteroscedasticity poses a challenge in ARIMA modeling by causing residual variance to be non-constant, leading to less efficient estimates. This issue often arises in time series data due to volatility, which measures data fluctuation over time. To address heteroscedasticity, models like ARCH and GARCH incorporate variance changes into forecasting. However, they lack the ability to capture asymmetry, the difference in impact between good and bad news on volatility. The APARCH model, on the other hand, addresses this by modeling volatility with asymmetry elements. Daily world crude oil prices, known for high volatility, serve as a case study for this research. By employing the APARCH model, the study aims to forecast these prices accurately. Results indicate that the APARCH(1,1) model outperforms the best GARCH model, ARCH(2), as it yields a smaller Mean Absolute Percentage Error (MAPE) of 6.033487. This highlights the superior accuracy of APARCH in forecasting data with heteroscedasticity issues, particularly in the context of daily crude oil prices.

1. PENDAHULUAN

Statistika adalah cabang ilmu dari Matematika yang terdiri dari teori serta metode terkait cara pengumpulan, meringkas, mengolah, menyajikan data serta menarik kesimpulan dan mengambil keputusan dari batas-batas resiko yang ada. Terdapat berbagai metode analisis data dalam ilmu Statistika salah satunya adalah analisis *time series*. Analisis *time series* merujuk pada pendekatan dalam Statistika yang dimanfaatkan untuk menganalisis data *time series*. Data *time series* ialah data yang didapat dengan urutan waktu dalam suatu periode waktu (Ardi, Santoso, & Prahutama, 2017).

Metode yang sering dimanfaatkan untuk menjalankan analisis *time series* ialah metode ARIMA (*Autoregressive Integrated Moving Average*) yaitu metode yang dengan penuh mengacuhkan variabel independen pada penciptaan model untuk peramalan. Bentuk umum model ARIMA ialah $ARIMA(p,d,q)$. Model $ARIMA(p,d,q)$ memiliki asumsi variansi *residual* bersifat konstan (homoskedastisitas). Namun seringkali anggapan ini tidak ditaati yang disebabkan pada data *time series* sering terjadi volatilitas.

Volatilitas ialah ukuran statistik untuk fluktuasi data pada jangka waktu tertentu. Kejadian volatilitas pada data *time series* seringkali mengakibatkan timbulnya *volatility clustering*. *Volatility clustering* merupakan kondisi terjadinya variabilitas data yang tinggi pada suatu periode tertentu daripada periode lain yang mengakibatkan kondisi yang sama dalam rentang waktu berikutnya. Kondisi ini disebut sebagai kasus heteroskedastisitas atau *time varying variance* (Hartati & Saluza, 2017). Hal ini menyebabkan pemodelan data *time series* menggunakan metode ARIMA Box-Jenkins kurang tepat jika data *time series*

mempunyai unsur heteroskedastisitas. Sehingga diperlukan metode yang lebih tepat untuk pemodelan data *time series* yang mengandung heteroskedastisitas.

Metode yang bisa dimanfaatkan untuk mengatasi masalah heteroskedastisitas pada data *time series* ialah metode *Autoregressive Conditional Heteroscedasticity* (ARCH). Metode ini dikenalkan oleh Engle (1982) yakni dengan cara memasukan unsur perubahan variansi dari waktu ke waktu ke dalam data *time series*. Bentuk umum model ini dikenal dengan ARCH(s). Kemudian model ARCH(s) dikembangkan oleh Bollerslev (1986) untuk menghindari identifikasi yang rumit pada orde yang besar, sehingga didapat model yang lebih sederhana yang disebut dengan GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*). Namun kedua model tersebut baik ARCH(s) dan GARCH(n,s) mempunyai kelemahan yakni tidak bisa menangkap unsur ketidaksimetrisan pada volatilitas (Tsay, 2005). Unsur ketidaksimetrisan adalah kondisi yang terjadi akibat adanya perbedaan antara efek *good news* (informasi terkait dampak positif terhadap pergerakan volatilitas) dan *bad news* (informasi terkait dampak negatif terhadap pergerakan volatilitas) (Ervina, Kusnandar & Imro'ah, 2020). Oleh karena itu diperlukan metode yang bisa menangkap masalah ketidaksimetrisan pada volatilitas. Salah satu metode yang bisa menangkap unsur ketidaksimetrisan adalah model *Asymmetric Power Autoregressive Conditional Heteroscedasticity* yang diperkenalkan oleh Ding, Granger, dan Engle pada tahun 1993. Model ini dikenal dengan model APARCH(n,s).

Model APARCH(n,s) pernah dimanfaatkan pada penelitian Pandia, Debararaja dan Martha (2019) dalam memodelkan *return* dari saham Bank BCA. Dalam penelitian tersebut didapat model terbaik yakni APARCH(1,1). Model tersebut menghasilkan model yang lebih baik daripada model GARCH(1,1) karena mampu menunjukkan efek ketidaksimetrisan. Najibullah, Ariansya, & Rizky (2023) juga menjalankan penelitian menggunakan model APARCH(n,s) untuk meramalkan volatilitas IHSG dan estimasi *Value-at-Risk*. Berdasarkan penelitian tersebut didapat jika nilai *value-at-risk* dengan model APARCH(n,s) mempunyai hasil yang lebih adaptif daripada model GARCH(n,s), hal terkait karena model APARCH(n,s) mampu menangkap kondisi ketidaksimetrisan volatilitas.

Secara umum pemodelan ARCH(s), GARCH(n,s), ataupun APARCH(n,s) dimanfaatkan pada bidang-bidang ekonomi. Hal terkait karena bidang ekonomi seringkali terjadi volatilitas, satu darinya adalah harga minyak mentah dunia. Minyak mentah adalah komoditi terbesar dan terpenting secara global. Harga minyak mentah mempunyai pengaruh penting bagi makronomi suatu negara. Penelitian terkait harga minyak mentah dunia juga pernah dilakukan oleh Zainal, Anggraini, & Rizki (2023) dengan memanfaatkan model GARCH(n,s). Hasilnya MAPE yang didapat dari model GARCH terbaik yakni GARCH(1,1) masih cukup besar dan menyarankan metode GARCH yang lain. Hal terkait kemungkinan diakibatkan karena data harga minyak mentah dunia mempunyai volatilitas data yang tinggi serta tersedia unsur ketidaksimetrisan. Salah satu metode yang disarankan untuk kasus data bervolatilitas tinggi seperti pada data harga minyak mentah dunia adalah model *Asymmetric Power Autoregressive Conditional Heteroscedasticity*, hal ini dikarenakan model APARCH mampu menangkap unsur ketidaksimetrisan pada model GARCH. Maka dari itu peneliti ini dilakukan untuk mendapatkan model APARCH untuk peramalan harga minyak mentah dunia serta tingkat akurasinya.

2. TINJAUAN PUSTAKA

Stasioneritas adalah sifat statistik dari data *time series* yang tidak berubah sepanjang rentang waktu yang diamati. Stasioneritas lemah mengacu pada kondisi tidak adanya perubahan yang signifikan terhadap data, sehingga mempunyai nilai rata-rata, dan variansi yang konstan seiring perubahan waktu (Verbeek, 2004). Pemeriksaan kestasioneritasan data

dilakukan dengan dua tahapan yaitu pemeriksaan kestasioneritasan data pada variansi dan pemeriksaan kestasioneritasan data pada rata-rata.

Pemeriksaan kestasioneritasan data pada variansi dilakukan dengan transformasi *Box-Cox*. Suatu data dikatakan stasioner pada variansi ketika nilai λ bernilai 1 atau mendekati 1. Menurut Box dan Cox (1964) penentuan nilai λ optimal untuk transformasi pada data dependen untuk variansi diselenggarakan dengan memanfaatkan Persamaan (1).

$$Z_t^\lambda = \begin{cases} \frac{(Z_t^\lambda - 1)}{\lambda}, & (\lambda \neq 0) \\ \log Z_t, & (\lambda = 0) \end{cases} \quad (1)$$

Pengujian stasioneritas dalam rata-rata dilakukan dengan uji akar unit (*unit root test*). pengujian akar unit yang digunakan adalah uji *Augmented Dickey-Fuller* (ADF) dengan hipotesis dan statistik uji sebagai berikut.

$H_0 : \psi = 0$ atau data tidak stasioner pada rata-rata

$H_1 : \psi < 0$ atau data stasioner pada rata-rata

Statistik uji ADF Persamaan (2):

$$\tau = \frac{\hat{\Psi}}{se(\hat{\Psi})} \quad (2)$$

Ketika data tidak stasioner dalam rata-rata maka dapat dilakukan *differencing*. Persamaan *differencing* pada orde ke- d bisa dituliskan seperti pada Persamaan (3) (Wei, 2006):

$$\nabla^d Z_t = (1 - B)^d Z_t \quad (3)$$

Autocorrelation Function (ACF) atau fungsi autokorelasi merupakan koefisien nilai hubungan linier dari observasi periode saat ini (Z_t) dengan observasi pada periode sebelumnya (Z_{t-k}) pada data *time series*. Nilai autokorelasi untuk populasi dihitung dengan memanfaatkan Persamaan (4) (Tsay, 2005):

$$r_k = \frac{\sum_{t=1}^{T-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^T (Z_t - \bar{Z})^2}, \quad k = 0, 1, 2, \dots, (T - 1) \quad (4)$$

Dengan :

T : Banyaknya pengamatan

k : Lag maksimum

t : Indeks waktu atau periode

Partial Autocorrelation Function (PACF) atau fungsi autokorelasi parsial merupakan nilai yang menunjukkan hubungan antara suatu hasil observasi dengan hasil observasi itu sendiri sesudah menghilangkan efek pengaruh dari hasil observasi sebelum-sebelumnya. Formula menghitung PACF ditunjukkan seperti persamaan berikut.

$$\hat{\phi}_{k,k} = \frac{r_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_{(k-j)}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_j} \quad (5)$$

Plot ACF dan plot PACF dapat digunakan sebagai identifikasi orde awal model ARIMA. Model ARIMA terdiri dari 4 model yaitu sebagai berikut.

a. Model *Autoregressive* (AR)

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (6)$$

b. Model *Moving Average* (MA)

$$Z_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (7)$$

c. Model *Autoregressive Moving Average* (ARMA)

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (8)$$

d. Model *Autoregressive Integrated Moving Average* (ARIMA)

$$(1 - B)^d(Z_t - \phi_1 Z_{t-1} - \dots - \phi_p Z_{t-p}) = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (9)$$

Parameter model ARIMA(p, d, q) diestimasi menggunakan metode *maximum likelihood*. Misal suatu observasi Z_1, Z_2, \dots, Z_T , sehingga fungsi kemungkinan *likelihood* (L) didefinisikan sebagai fungsi kepedakatan peluang bersama yang didapat dari data yang diamati. Untuk model ARIMA(p, d, q) fungsi kemungkinan L adalah fungsi dari ϕ, θ, μ , dan σ_ε^2 yang ditunjukkan seperti pada Persamaan (10) (Criyer & Chan, 2008):

$$L = f(Z_1, Z_2, \dots, Z_T) = \prod_{t=1}^T f(Z_t) \quad (10)$$

Pengujian signifikan parameter dilakukan untuk mengetahui apakah parameter dari model berpengaruh terhadap variabel dependen. Pengujian signifikan parameter dilakukan dengan hipotesis 1 yaitu parameter signifikan terhadap variabel dependen ($H_1: \phi_i \neq 0, i = 1, 2, \dots, p$), dengan statistik uji seperti Persamaan (11).

$$t - test = \frac{\hat{\phi}_i}{se(\hat{\phi}_i)} \quad (11)$$

Uji asumsi *white noise* dilakukan untuk menguji apakah *residual* yang didapatkan oleh model bersifat *random* (acak) (Dahoklory, Suryowati, & Becti, 2016). Model ARIMA(p, d, q) mempunyai asumsi dasar jika *residual* model harus bersifat *white noise*. *White noise* berarti jika tidak ada korelasi antar *residual*, dengan nilai rata-rata nol dan variansi konstan. Pengujian asumsi *white noise* dilakukan dengan uji *Ljung-Box* dengan hipotesis antara lain (Ljung & Box, 1978):

$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$ (*Residual* bersifat *white noise*)

$H_1 : \text{Minimal ada satu } \rho_k \neq 0$ (*Residual* tidak bersifat *white noise*), dengan $k = 1, 2, \dots, m$

$$Q = T(T + 2) \sum_{k=1}^m (T - k)^{-1} r_k^2 \quad (12)$$

Dimana :

M : Lag optimal yang ditaksir pada uji *Ljung-Box*

Uji efek ARCH dilakukan untuk mendeteksi keberadaan unsur heteroskedastisitas serta adanya efek ARCH. Uji efek ARCH yang digunakan Uji ARCH *Lagrange Multiplier* (LM) dengan hipotesis dan statistik uji sebagai berikut.

$H_0 : a_1 = \dots = a_k = 0$ (Variansi *residual* sama atau tidak ada efek ARCH)

$H_1 : \text{Minimal ada satu } a_i \neq 0, i = 1, 2, 3, \dots, k$ (Variansi *residual* tidak sama atau ada efek ARCH)

Statistik uji pada pengujian ARCH LM :

$$LM = \frac{(SSR_0 - SSR_1) \cdot k}{\frac{SSR_1}{T - 2k - 1}} \quad (13)$$

Model ARCH (*Autoregressive Conditional Heteroscedasticity*) merupakan metode yang dikembangkan oleh Engle (1982) dengan cara memasukan unsur perubahan variansi dari waktu ke waktu ke dalam data *time series*. Model ARCH pada orde ke- s dinotasikan dengan ARCH(s) yaitu sebagai berikut.

$$Z_t = \hat{Z}_t + \varepsilon_t$$

dimana :

$$\varepsilon_t = \sigma_t X_t, X_t \sim N(0, 1)$$

Sehingga secara umum model ARCH pada orde ke- s ditulis dengan notasi ARCH(s) yang didefinisikan berdasarkan Persamaan (14).

$$\sigma_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_s \varepsilon_{t-s}^2 \quad (14)$$

Model GARCH dinotasikan dengan GARCH(n, s) yang mana berarti pemodelan *time series* dengan kondisi heteroskedastisitas pada waktu ke- t dari *residual* kuadrat serta variansi

bersyarat waktu sebelumnya berguna sebagai fungsi linier. Secara umum model GARCH(n,s) didefinisikan dengan Persamaan (15):

$$\sigma_t^2 = \omega + \sum_{i=1}^s \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^n \beta_j \sigma_{t-j}^2 \quad (15)$$

Pengujian efek asimetris dengan *sign bias test* diselenggarakan berdasarkan model persamaan dari *residual* kuadrat model ARCH(s) atau GARCH(n,s) yakni antara lain (Brooks, 2008).

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

H_1 : Paling sedikit ada satu $\varphi_j \neq 0$, untuk $j=1,2,3$ (*Residual* bersifat asimetris)

Statistik uji:

$$Lm = T \cdot R^2 \quad (16)$$

Model APARCH dapat digunakan ketika *residual* pada model *time series* memiliki kondisi heteroskedastisitas dan tidak simetris. Model APARCH diperkenalkan pada tahun 1993 oleh Ding, Granger dan Engle yang dapat digunakan untuk menangani masalah ketidaksimetrisan secara umum yang terjadi pada *residual* model *time series*. Secara umum model persamaan APARCH dinotasikan dengan APARCH(n,s) yang didefinisikan dengan Persamaan (17):

$$\sigma_t^\delta = \omega + \sum_{i=1}^s \alpha_i (|\varepsilon_{t-i}| - \gamma_i \varepsilon_{t-i})^\delta + \sum_{j=1}^n \beta_j \sigma_{t-j}^\delta \quad (17)$$

Quasi-Maximum Likelihood Estimation (QMLE) merupakan estimasi yang dimanfaatkan untuk menguatkan metode estimasi *maximum likelihood* dimana ketika hasil estimasi tidak mengikuti distribusi sebenarnya (Martin, Hurn, & Harris, 2011). Dalam penentuan nilai estimasi parameter, QMLE tetap memanfaatkan estimasi *maximum likelihood* sebagai dasarnya. Estimasi *quasi-maximum likelihood* pada pemodelan keluarga GARCH diselenggarakan dengan fungsi gaussian *quasi-likelihood* seperti pada Persamaan (18) (Franco & Zakoian, 2004).

$$QL(\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n | \sigma_\varepsilon^2) = \prod_{t=1}^T (2\pi\sigma_\varepsilon^2)^{-\frac{1}{2}} \exp\left(-\frac{\varepsilon_t^2}{2\sigma_\varepsilon^2}\right) \quad (18)$$

Akaike's Information Criterion (AIC) ialah cara guna mengidentifikasi kebaikan model. Sedangkan *Bayesian Information Criterion* (BIC) merujuk pada pemilihan model terbaik yang diselenggarakan dengan pendekatan *Maximum Likelihood*. Secara matematis persamaan kriteria AIC dan kriteria BIC dituliskan seperti Persamaan (19) dan Persamaan (20) (Burnham & Anderson, 2004):

$$AIC = -2 \log(L) + 2k \quad (19)$$

$$BIC = -2 \log(L) + k \log(T) \quad (20)$$

Uji *likelihood ratio* adalah pengujian yang dilakukan untuk membandingkan dua model yang didapat dengan memanfaatkan nilai *likelihood*. Pengujian *likelihood ratio* menjadi alternatif ketika terjadi perbedaan nilai AIC dan BIC terkecil pada model. Statistik uji *likelihood ratio* bisa diamati dari Persamaan (21).

$$G = -2 \ln \left(\frac{L_{model1}}{L_{model2}} \right) = 2(\ln L_{model2} - \ln L_{model1}) \quad (21)$$

Hipotesis untuk pengujian *likelihood ratio* yakni antara lain.

H_0 : Model pertama lebih baik daripada model kedua

H_1 : Model kedua lebih baik daripada model pertama

MAPE merujuk pada ukuran ketetapan yang biasa dimanfaatkan untuk mengetahui tingkat persentase penyimpangan hasil nilai prediksi terhadap nilai realisasi. Menghitung nilai MAPE dilakukan dengan formula berikut (Makridakis, Hibon, & Moser, 1979).


$$MAPE = \frac{1}{T} \sum_{t=1}^T \left(\frac{Z_t - \hat{Z}_t}{Z_t} \right) \times 100\% \quad (22)$$

3. METODE PENELITIAN

Data dalam penelitian ini adalah data harga harian minyak mentah dunia dari bulan Januari 2021 hingga Oktober 2023 yang didapat dari finance.yahoo.com. Langkah-langkah analisis *time series* dengan model APARCH adalah antara lain.


- a. Mencari model terbaik model APARCH
 1. Mengumpulkan dan menyiapkan data untuk penelitian.
 2. Menjalankan Statistika deskriptif dan eksplorasi data.
 3. Menjalankan pengujian stasioneritas dengan transformasi *Box-Cox* seperti Persamaan (1) dan uji akar unit seperti Persamaan (2). Jika data sudah stasioner sehingga lanjut ke tahap 4, jika data tidak stasioner sehingga perlu diselenggarakan *differencing* dengan Persamaan (3).
 4. Pemodelan ARIMA Box-Jenkins.
 - a. Mengidentifikasi ordel awal model ARIMA menggunakan plot ACF dan plot PACF dengan nilai ACF dan PACF dihitung seperti Persamaan (4) dan Persamaan (5).
 - b. Menjalankan estimasi parameter model ARIMA menggunakan metode *Maximum likelihood* (MLE) seperti persamaan (10).
 - c. Menjalankan pengujian signifikan parameter pada model ARIMA dengan memanfaatkan persamaan (11).
 5. Pemilihan model ARIMA terbaik dengan memanfaatkan nilai AIC dan BIC seperti Persamaan (19) dan Persamaan (20).
 6. Menjalankan pengujian asumsi *residual* model ARIMA. Pengujian diselenggarakan dengan menguji asumsi *white-noise* dengan persamaan (2).
 7. Menjalankan pengujian efek ARCH pada model ARIMA terbaik. Pengujian menggunakan Uji ARCH *LM* seperti persamaan (13). Jika tersedia efek ARCH pada model ARIMA sehingga bisa dilanjutkan ke tahap 8. Namun jika tidak mengandung efek ARCH maka selesai..
 8. Pemodelan ARCH/GARCH.
 - a. Menjalankan estimasi parameter model ARCH atau GARCH dengan memanfaatkan QMLE seperti persamaan (18).
 - b. Menjalankan uji signifikan parameter pada model ARCH/GARCH menggunakan persamaan (11).
 - c. Memilih model ARCH atau GARCH terbaik berdasarkan nilai AIC dan BIC terkecil seperti Persamaan (19) dan Persamaan (20).
 9. Uji efek asimetris pada model menggunakan Persamaan (16). Jika model asimetris sehingga bisa dilanjutkan ke model APARCH. Jika simetris sehingga cukup dengan ARCH atau GARCH.
 10. Pemodelan dan estimasi parameter APARCH seperti Persamaan (17). Pada tahap ini juga diselenggarakan uji signifikansi parameter model APARCH seperti Persamaan (11).
 11. Menentukan model terbaik dengan memanfaatkan AIC dan BIC terkecil dari model APARCH yang terbentuk seperti Persamaan (19) dan Persamaan (20).
 12. Hasil model APARCH terbaik dan interpretasi.
- b. Menghitung akurasi dari model APARCH yang terbaik
 1. Menjalankan peramalan untuk data *testing* dengan model APARCH terbaik.
 2. Menghitung tingkat akurasi dengan memanfaatkan perhitungan MAPE seperti Persamaan (22).
 3. Interpretasi hasil dan kesimpulan.

4. HASIL DAN PEMBAHASAN



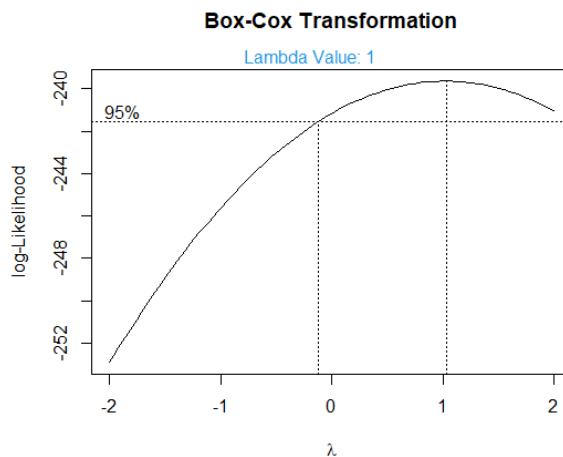
Gambar 1. Plot harga minyak mentah dunia

Berdasarkan Gambar 1 memperlihatkan jika harga harian minyak mentah dunia terjadi fluktuasi setiap waktu dan terjadi *volatilitas clustering* yang terjadi pada sekitar bulan Maret 2022 hingga Agustus 2022. *Volatilitas clustering* merupakan perubahan suatu data *time series* yang sangat signifikan, sehingga mempunyai nilai yang relatif lebih tinggi daripada periode sebelumnya dan sesudahnya.



Gambar 2. Plot transformasi data

Berdasarkan Gambar 2 bisa diamati jika nilai *lambda* optimal yang didapat bernilai -0.3 yang artinya data belum stasioner dalam varians sehingga diperlukan transformasi agar data menjadi stasioner dalam varians. Setelah ditransformasi diperoleh hasil pemeriksaan stasioneritas dalam varians seperti Gambar 3.



Gambar 3. Plot transformasi 1

Berdasarkan hasil transformasi data didapat nilai λ optimal bernilai 1 yang artinya jika data sudah stasioner dalam varians.


Hasil perhitungan statistik uji ADF untuk mengetahui kestasioneritasan data dalam rata-rata dapat dilihat pada Tabel 1.

Tabel 1. Hasil uji ADF

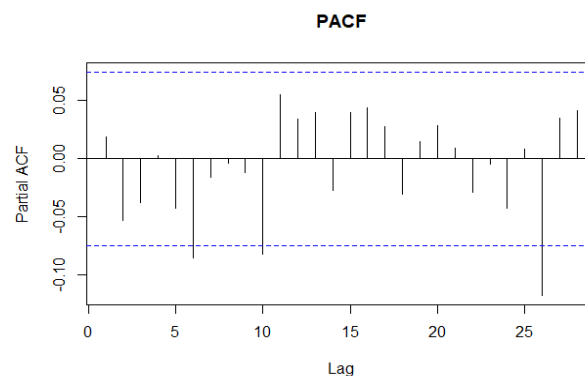
Data	Statistik Uji	Nilai Kritis ADF	p -value
Transformasi	-2.1365	-2.863	0.5205
Differencing	-9.807	-2.863	0.01

Berdasarkan hasil yang didapat dengan taraf nyata sejumlah 5% ($\alpha = 0.05$) sehingga bisa disimpulkan jika H_0 diterima. Hal terkait berarti data tidak stasioner dalam rata-rata maka dilakukan *differencing*. Berdasarkan hasil uji ADF pada data *differencing* yang didapat dengan taraf nyata sejumlah 5% ($\alpha = 0.05$) sehingga bisa disimpulkan jika H_0 ditolak. Hal terkait berarti jika data sesudah dilakukan *differencing* sudah stasioner dalam rata-rata.

Identifikasi pemodelan ARIMA dilakukan dengan melihat plot ACF dan plot PACF untuk menentukan orde awal model ARIMA.



Gambar 4. Plot ACF



Gambar 5. Plot PACF

Berdasarkan Gambar 4 dan Gambar 5 bisa diamati jika pada plot ACF plot terjadi *cut-off* pada lag ke-6, hal terkait menunjukkan jika orde MA maksimal sejumlah 6. Sementara plot PACF juga terjadi *cut-off* pada lag ke-6 yang mengidentifikasi adanya model AR dengan orde maksimal sejumlah 6.

Berdasarkan hasil estimasi yang dilakukan diperoleh model ARIMA dengan parameter yang signifikan menggunakan taraf nyata sejumlah 5% ($\alpha = 0.05$) didapat model ARIMA(1,1,1) dan ARIMA(3,1,3). Berdasarkan pemilihan model terbaik dengan AIC dan BIC terkecil terjadi perbedaan di mana model dengan nilai AIC terkecil terdapat pada model ARIMA(1,1,1) sedangkan nilai BIC terkecil terdapat pada model ARIMA(3,1,3), sehingga dilakukan pengujian menggunakan uji *likelihood ratio*.

Berdasarkan statistik uji didapat hasil pengujian *likelihood ratio* diperoleh nilai *p-value* sebesar 0.009358 yang artinya bahwa model kedua atau model ARIMA(3,1,3) adalah model terbaik.

Berdasarkan statistik uji untuk pengujian asumsi *white noise* dan efek ARCH dapat dilihat pada tabel berikut.

Tabel 2. Hasil *White noise* dan efek ARCH

Uji	Statistik Uji	Chi-Square	p-value
<i>Ljung-Box</i>	1.1084	3.148	0.2924
ARCH LM	29.222	21.026	0.003652

Berdasarkan hasil yang didapat dengan taraf nyata sejumlah 5% ($\alpha = 0.05$) sehingga disimpulkan jika H_0 diterima. Hal terkait berarti *residual* model ARIMA terbaik sudah memenuhi asumsi *white noise* atau tidak adanya autokorelasi pada *residual* model.

Berdasarkan hasil yang didapat dengan taraf nyata sejumlah 5% ($\alpha = 0.05$) sehingga disimpulkan jika H_0 ditolak. Hal terkait berarti tersedia efek ARCH pada *residual* model ARIMA terbaik.

Berdasarkan hasil pengujian didapat jika terdapat efek ARCH maka dapat dilakukan pemodelan ARCH dan GARCH. Identifikasi orde pada model ARCH dan GARCH dilakukan dengan menggunakan plot ACF dan plot PACF dari *residual* kuadrat model ARIMA terbaik. Berdasarkan estimasi yang dilakukan diperoleh 3 model ARCH dan GARCH yang memiliki parameter signifikan yakni model ARCH(1), ARCH(2), dan GARCH(0,1). Untuk melihat model terbaik diselenggarakan dengan mengamati nilai AIC dan BIC dari kedua model yang didapat.

Pemilihan model ARCH dan GARCH terbaik diamati dengan nilai AIC dan BIC terkecil. Hasil nilai AIC dan BIC model ARCH dan GARCH bisa diamati pada Tabel 3.

Tabel 3. Perbandingan AIC dan BIC ARCH

Model	AIC	BIC
ARCH(1)	-9.6062	-9.5930
ARCH(2)	-9.6247	-9.6049
GARCH(0,1)	-9.5990	-9.5858

Dari Tabel 3 dapat diketahui jika model terbaik adalah model ARCH(2). Hal terkait karena model ARCH(2) mempunyai nilai AIC dan BIC terkecil. Langkah berikutnya yang dilakukan adalah dengan menjalankan pengujian efek asimetris pada model GARCH terbaik.

Pengujian efek asimetris pada model ARCH diselenggarakan untuk mengetahui apakah *residual* mengandung efek asimetris atau tidak. Hasil pengujian efek asimetris untuk model ARCH(2) adalah antara lain.

Tabel 4. Hasil *sign bias test*

<i>Sign Bias Test</i>	Statistik Uji	p-value
<i>Sign Bias</i>	2.1158	0.03472
<i>Negatif Sign Bias</i>	0.9927	0.32121
<i>Positive Sign Bias</i>	1.2066	0.22799
<i>Joint Effect</i>	4.5162	0.21085

Berdasarkan pada Tabel 4 bisa diamati jika model *residual* model GARCH terbaik mempunyai efek asimetris. Efek ketidaksimetrisan terjadi pada *sign bias*. Karena model

GARCH mempunyai efek asimetris, sehingga pemodelan bisa dilanjutkan ke model APARCH untuk menangkap efek ketidaksimetrisan pada volatilitas.

Pemodelan APARCH diselenggarakan dengan menjalankan estimasi parameter. Identikasi orde model APARCH diselenggarakan berdasarkan plot ACF dan PACF kuadrat *residual* model ARIMA seperti halnya model ARCH dan GARCH. Berdasarkan hasil estimasi yang dilakukan pemilihan model terbaik APARCH dapat dilihat pada tabel berikut.

Tabel 5. Perbandingan AIC dan BIC model APARCH

Model	AIC	BIC
APARCH(1,0)	-9.5638	-9.5374
APARCH(2,0)	-9.5750	-9.5354
APARCH(1,1)	-9.6432	-9.6101
APARCH(1,2)	-9.6271	-9.5874
APARCH(2,1)	-9.6353	-9.5891
APARCH(2,2)	-9.6228	-9.6023

Dari Tabel 5 model dengan nilai AIC dan BIC terkecil dimiliki oleh model APARCH(1,1). Sehingga didapat model APARCH terbaik untuk data harga harian minyak mentah dunia adalah model APARCH(1,1).

Langkah terakhir yang diselenggarakan adalah menghitung tingkat akurasi model APARCH terbaik untuk mengetahui kebaikan model untuk menjalankan peramalan harga minyak mentah dunia. Hasil perhitungan MAPE dari model terbaik ditunjukkan seperti tabel berikut.

Tabel 6. Hasil perhitungan MAPE

Model	Nilai MAPE
ARCH(2)	6.740954
APARCH(1,1)	6.033487

Dari Tabel 6 bisa diamati jika peramalan dengan memanfaatkan APARCH(1,1) mempunyai nilai MAPE sejumlah 6.033487. Sedangkan hasil peramalan menggunakan model ARCH(2) mempunyai nilai MAPE sebesar 6.740954. Hal terkait menunjukkan jika model APARCH lebih baik jika daripada model ARCH untuk peramalan harga minyak mentah dunia yang mempunyai kasus heteroskedastisitas yang tidak simetris.

5. KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan model APARCH terbaik untuk peramalan harga minyak mentah dunia harian adalah APARCH(1,1) dengan model rata-rata yaitu model ARIMA(3,1,3). Model APARCH(1,1) adalah sebagai berikut.

$$\sigma_t^{2.552359} = 0.056704(|\varepsilon_{t-1}| + 0.011692\varepsilon_{t-1})^{2.552359} + 0.894552\sigma_{t-1}^{2.552359}$$

Berdasarkan model APARCH terbaik dipeorleh nilai akurasi MAPE sebesar 6.033487. Nilai ini mempunyai nilai yang lebih kecil daripada nilai MAPE model ARCH terbaik yakni ARCH(2) yang bernilai 6.740954. Maka dapat disimpulkan bahwa model APARCH lebih baik daripada model GARCH untuk kasus heteroskedastisitas yang mempunyai efek asimetrisi.

DAFTAR PUSTAKA

Ardi, T. Santoso, R. dan Prahutama, A. 2017. Implementasi Subset *Autoregressive* Menggunakan Paket Fitar. *Jurnal Gaussian*, Vol. 6, No. 4, 510-519. DOI : 10.14710/j.gauss.6.4.510-519

- Bollerslev, T. 1986. Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics* 31, 3077327. DOI: 10.1016/0304-4076(86)90063-1
- Burnham, K. P. dan Anderson, D. R. 2004. *Multimodel Inference. Sociological Methods & Research*, 33(2), 261–304. DOI:10.1177/0049124104268644
- Dahoklory, D. Suryowati, K. dan Bekti, R. D. 2016. Analisis Trend dan ARCH-GARCH Untuk Meramalkan Jumlah Pasangan Usia Subur Di Daerah Istimewa Yogyakarta. *Jurnal Statistika Industri dan Komputasi* Vol. 1, No. 1, PP. 11-22.
- Ding, Z. Granger, C. W.J. dan Engle, R. F. (1993). A Long Memory Property of Stock Market Returns and a New Model. *Journal of Empirical Finance*, 2(1), 98. DOI:10.1016/0927-5398(95)90049-7
- Engle, R.F. 1982. Autoregressive Conditional Heteroskedasticity with Estimates of The Variance of U.K. *Inflation, Econometrica*, 50, 987-1008. DOI: 10.2307/1912773
- Ervina, Kusnandar, D. dan Imro'ah, N. (2020). Peramalan Volatilitas Saham Menggunakan Model Threshold Generalized Autoregressive Conditional Heteroscedasticity. *Buletin Ilmiah Mat. Stat. dan Terapannya (Bimaster)* Vol. 09, No. 1, Hal 79-86.
- Franco, C. dan Zakoian, J. M. (2004). Maximum Likelihood Estimation of Pure GARCH and ARMA-GARCH Processes. *JOURNAL ARTICLE* Vol. 10, No. 4, pp. 605-637. DOI:10.3150/bj/1093265632
- Hartati. Dan Saluza, I. 2017. Aplikasi GARCH dalam Mengatasi Volatilitas Pada Data Keuangan. *Jurnal Matematika* Vol. 7, No. 2, pp. 107-118. DOI: 10.24843/JMAT.2017.v07.i02.p87
- Ljung, G. M. dan Box, G. E. P. (1978). On a Measure of Lack of Fit in Time Series Models. *Biometrika*, Vol. 65, No. 2, pp. 297-303. DOI: 10.2307/2335207
- Makridakis, S. Hibon, M. dan Moser, C. 1976. Accuracy of Forecasting: An Empirical Investigation. *Journal of the Royal Statistical Society. Series A (General)*, Vol. 142, No. 2, pp. 97-145. DOI :10.2307/2345077
- Martin., V. L. Hurn, A. S. dan Harris, D. 2004. *Econometric Modelling with Time Series Specification, Estimation and Testing*. Cambridge University Press.
- Najibullah. Ariansyah, R. dan Rizky, F. 2023. Peramalan Volatilitas IHSG Dan Estimasi Value-At-Risk Menggunakan Model Student Aparch. *Jurnal Hei Ema*, Vol. 2 No. 1.
- Pandia, M. D. B. Debatara, N. N. dan Martha, S. 2019. Pemodelan Volatilitas Saham Menggunakan Model Asymmetric Power Autoregressive Conditional Heteroscedasticity. *Buletin Ilmiah Mat, Stat, Dan Terapannya (Bimaster)*, Vol. 08, No. 1.
- Tsay, R.S. 2005. *Analysis Of Financial Time Series Second Edition*. John Wiley And Sons, Inc., Canada.
- Verbeek, M. 2004. *A Guide to Modern Econometrics*. Second Edition. Chichester: John Wiley & Sons, Ltd.
- Wei, W. W. 2006. *Time Series Analysis Univariate and Multivariate Methods*. Canada: Addison Wesley Publishing Company.
- Zainal, P. H. Anggraini, Y. dan Rizki, A. 2023. Penerapan Metode Generalized Autoregressive Conditional Heteroskedasticity Untuk Peramalan Harga Minyak Mentah Dunia. *Xplore Journal Of Statistics*, Vol. 12, No. 1, 12-21