

Pemodelan ARFIMA dengan Estimasi Parameter Pembeda Menggunakan Metode *Geweke Porter-Hudak*

Nur Kamilah Oktaviani, Nur Azizah Komara Rifai*

Prodi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Bandung, Indonesia.

ARTICLE INFO

Article history :

Received : 9/5/2024
Revised : 18/7/2024
Published : 31/7/2024



Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License.

Volume : 4
No. : 1
Halaman : 11 - 20
Terbitan : **Juli 2024**

ABSTRAK

Peramalan adalah analisis yang berkaitan dengan penggunaan data historis untuk menemukan hubungan, kecenderungan, dan pola data yang terstruktur. Metode peramalan yang umum digunakan yaitu ARIMA, Model ARIMA hanya dapat menjelaskan data deret waktu dengan memori jangka pendek. Model ARFIMA merupakan pengembangan dari model ARIMA yang memiliki kelebihan dapat menjelaskan deret waktu jangka pendek (*short memory*) maupun jangka panjang (*long memory*), dengan nilai *differencing* merupakan bilangan riil. Penelitian ini bertujuan untuk memodelkan menggunakan metode *Autoregressive Fractionally Integrated Moving Average* (ARFIMA), dengan estimasi parameter pembeda yang digunakan yaitu Geweke dan Porter-Hudak (GPH). Data yang digunakan dalam penelitian ini adalah Volume Impor Migas pada tahun 2012 hingga 2023. Berdasarkan penelitian yang telah dilakukan dapat disimpulkan bahwa model yang terpilih untuk peramalan volume impor migas, yaitu ARFIMA (0;0,421;1) dengan nilai AIC sebesar 1795,294.

Kata Kunci : ARFIMA; Jangka Panjang; Volume Impor Migas.

ABSTRACT

Forecasting is an analysis related to the use of historical data to find relationships, trends, and structured data patterns. The commonly used forecasting method is ARIMA. The ARIMA model can only explain time series data with short-term memory. The ARFIMA model has been developed from the ARIMA model, offering the advantage of explaining both short-term and long-term time series, with differencing values being real numbers. This study aims to model using the Autoregressive Fractionally Integrated Moving Average (ARFIMA) method, estimating the differencing parameters used, namely Geweke and Porter-Hudak (GPH). The data used in this study was the volume of oil and gas imports from 2012 to 2023. Based on the research, it was concluded that the model chosen for forecasting the volume of oil and gas imports was ARFIMA (0;0.421;1) with an AIC value of 1795,294.

Keywords : ARFIMA; Long Memory; Volume of Oil and Gas Imports.

Copyright© 2024 The Author(s).

A. Pendahuluan

Peramalan merupakan suatu metode untuk memperkirakan situasi atau kejadian di masa yang akan datang berdasarkan data historis atau data sebelumnya [1]. Metode peramalan yang umum digunakan merupakan pemodelan data *time series*. *Time series* atau deret waktu adalah kumpulan pengamatan yang dilakukan secara berurutan berdasarkan waktu dalam interval waktu tertentu, seperti harian, mingguan, bulanan, tahunan, atau periode waktu lainnya [2].

Terdapat metode-metode yang telah dikembangkan dalam analisis deret waktu adalah *Exponential Smoothing*, *Autoregressive (AR)*, *Moving Average (MA)*, ARMA dan ARIMA. Dari berbagai metode tersebut, metode yang umum digunakan adalah ARIMA [3]. Model ARIMA hanya dapat menjelaskan data deret waktu dengan memori jangka pendek (*short memory*), biasanya ditunjukkan oleh plot ACF yang menurun secara eksponensial atau membentuk gelombang sinus, data deret waktu akan di stasionerkan dengan melakukan *differencing*, dengan nilai *differencing* yaitu bilangan bulat non-negatif [4]. Namun, terdapat beberapa data yang tidak stasioner dan memiliki plot ACF yang menurun secara perlahan atau hiperbolik yang dikategorikan sebagai data deret waktu berpola memori jangka panjang (*long memory*) [5].

Data deret waktu dengan memori jangka panjang terjadi saat data mempunyai korelasi yang kuat pada waktu pengamatan yang panjang. Granger dan Joyeux pada tahun 1980, serta Hosking 1981 mengembangkan model yang sesuai untuk proses dengan memori jangka panjang, dikenal sebagai *Autoregressive Fractionally Integrated Moving Average (ARFIMA)*. Model ARFIMA ini mampu dengan baik menjelaskan deret waktu berupa *short memory* maupun *long memory*, dengan menggunakan parameter *differencing* sebagai bilangan riil [6]. Estimasi parameter pembeda dalam model ARFIMA dapat dilakukan dengan menggunakan metode Geweke dan Porter-Hudak (GPH). Metode GPH memiliki kelebihan dibandingkan dengan metode lain seperti Metode *Maximum Likelihood* dan *Nonlinear Least Square* adalah fleksibilitas dalam estimasi parameter. Dalam metode GPH, estimasi parameter pembeda dapat dilakukan secara langsung tanpa mengetahui parameter p dan q terlebih dahulu [7].

Berdasarkan penelitian Kartika, Yasin & Maruddani [8] melakukan pemodelan ARFIMA untuk meramalkan perkembangan Pandemi Covid-19 di Indonesia. Hasil penelitian tersebut menghasilkan model terbaik ARFIMA(1,d,0) dengan nilai *differencing* sebesar 0.489 untuk kasus sembuh dan nilai *differencing* sebesar 0.429 untuk kasus yang meninggal. Selain data kesehatan, metode pada analisis data deret waktu seperti ARFIMA juga dapat diterapkan pada berbagai jenis data lainnya, termasuk data cuaca dan iklim keuangan, transportasi, dan ekonomi.

Kegiatan ekonomi merupakan kegiatan yang dilakukan pada setiap negara, salah satunya adalah kegiatan perdagangan Internasional. Perdagangan Internasional adalah suatu bentuk kegiatan yang dilakukan oleh suatu negara dan negara lain guna mencukupi kebutuhan negara tersebut [9]. Perdagangan Internasional meliputi 2 aktivitas, yaitu aktivitas ekspor dan impor. Ekspor adalah tindakan menjual barang atau jasa ke negara lain. Sedangkan, Impor adalah arus masuknya berbagai komoditas dan jasa ke pasar suatu negara untuk keperluan konsumsi serta bahan modal yang digunakan sebagai bahan baku produksi dalam negeri [10]. Badan Pusat Statistik (BPS) melaporkan volume impor minyak dan gas (migas) Indonesia meningkat 5,61 juta ton menjadi 47,74 juta ton pada 2022, sedangkan volume ekspornya turun 8,66% menjadi 24,56 juta ton [11].

Berdasarkan latar belakang di atas, maka rumusan masalah dalam penelitian ini adalah sebagai berikut: "Bagaimana pemodelan *Autoregressive Fractionally Integrated Moving Average (ARFIMA)* dengan estimasi parameter pembeda menggunakan Geweke Porter-Hudak (GPH) pada data volume impor migas?". Selanjutnya, tujuan dalam penelitian ini adalah memperoleh model terbaik *Autoregressive Fractionally Integrated Moving Average (ARFIMA)* dengan estimasi parameter pembeda menggunakan Geweke Porter-Hudak (GPH) pada data volume impor migas.

B. Metode Penelitian

Peneliti menggunakan metode *Autoregressive Fractionally Integrated Moving Average (ARFIMA)* dengan estimasi parameter pembeda menggunakan Geweke Porter-Hudak (GPH).

Model ARFIMA

Model ARFIMA merupakan pengembangan dari model ARIMA. Model ARFIMA(p,d,q) dengan nilai p dan q adalah bilangan bulat non-negatif, serta nilai d berupa bilangan riil yang berada pada interval $0 < d < 0,5$ [6]. Bentuk umum dari model ARFIMA(p, d, q) sebagai berikut [12]:

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)e_t \tag{1}$$

dengan,

t : indeks dari pengamatan

d : parameter pembeda (bilangan pecahan)

Z_t : nilai variabel pada waktu ke-t

B : *backward shift* operator

$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ adalah polinomial *autoregressive* ke-p

$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ adalah polinomial *moving average* ke-q

$(1 - B)^d = \sum_{k=0}^{\infty} \binom{d}{k} (-1)^k B^k$: operator *differencing* bernilai pecahan

Fractional Differencing

Untuk suatu nilai d bernilai pecahan, operator fraksional diferensi $(1 - B)^d$ atau ∇^d merupakan filter pembeda pada model ARFIMA(p,d,q) menggambarkan adanya jangka panjang (long memory) dalam deret. Filter ini diekspansikan sebagai perluasan deret binomial didefinisikan sebagai berikut [6]:

$$\nabla^d = (1 - B)^d = \sum_{k=0}^{\infty} \binom{d}{k} (-1)^k B^k, \quad d > k \tag{2}$$

Dengan $\binom{d}{k} = \frac{d!}{(d-k)!k!} = \frac{\Gamma(d+1)}{\Gamma(k+1)\Gamma(d-k+1)}$ dan $\Gamma(x)$ merupakan fungsi gamma

Apabila persamaan (2) dijabarkan maka diperoleh [7],

$$(1 - B)^d = 1 + \sum_{k=1}^{\infty} \frac{\Gamma(-d + k)}{\Gamma(-d)k!} B^k \tag{3}$$

Untuk k = 1 diperoleh, $\frac{\Gamma(-d+1)}{\Gamma(-d)1!} = \frac{(-d)!}{(-d-1)!1!} = -d$

Untuk k = 2 diperoleh, $\frac{\Gamma(-d+2)}{\Gamma(-d)2!} = \frac{(-d+1)!}{(-d-1)!2!} = \frac{-d(1-d)}{2}$

Untuk k = 3 diperoleh, $\frac{\Gamma(-d+3)}{\Gamma(-d)3!} = \frac{(-d+2)!}{(-d-1)!3!} = \frac{-d(1-d)(2-d)}{6}$

Dan seterusnya, sehingga diperoleh

$$(1 - B)^d = 1 - dB - \frac{1}{2}d(1-d)B^2 - \frac{1}{6}d(1-d)(2-d)B^3 - \dots$$

Penelitian ini menggunakan data sekunder yang bersumber dari *website* Badan Pusat Statistik Indonesia (www.bps.go.id) dengan data yang digunakan yaitu volume impor migas di Indonesia dari bulan Januari 2012 hingga Desember 2023. Data ini berjumlah 144 pengamatan. Penelitian ini menggunakan *software R-Studio* dan Minitab dengan tahapan sebagai berikut:

Kesatu, mendeskripsikan karakteristik dari data dan melakukan eksplorasi data dengan melihat plot deret waktu data volume impor migas.

Kedua, melakukan pemeriksaan kestasioneran data menggunakan uji *Augmented Dickey Fuller* (ADF). Jika data tidak stasioner dalam varians, maka perlu dilakukan Transformasi Box-Cox. Jika data tidak stasioner dalam rata-rata, maka perlu dilakukan *differencing* untuk data berupa *short memory* menggunakan d bernilai bilangan bulat dan untuk data berupa *long memory* menggunakan d bernilai pecahan.

Ketiga, mengidentifikasi *long memory* menggunakan plot *Autocorrelation Function* (ACF) dan perhitungan nilai *Hurst*.

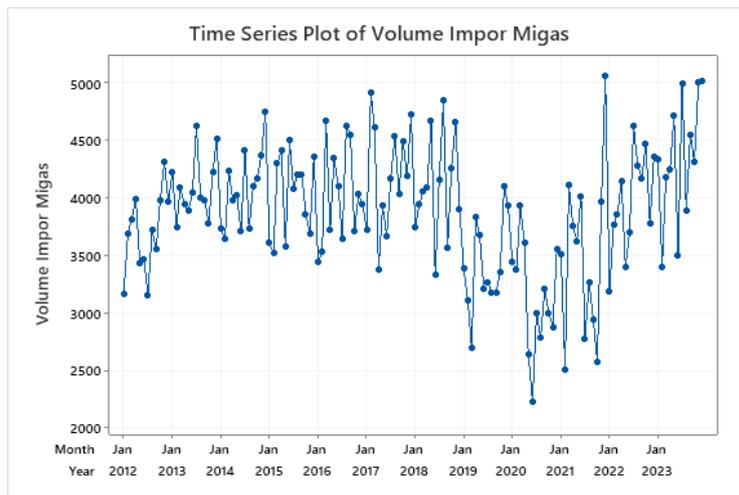
Keempat, pemodelan ARFIMA dengan Langkah sebagai berikut. Menentukan estimasi parameter pembeda (d) menggunakan metode Geweke dan Porter-Hudak (GPH). Menentukan parameter (p, q) berdasarkan plot ACF dan PACF dari data yang telah mengalami *differencing* menggunakan GPH. Estimasi parameter untuk model ARFIMA dan uji signifikansi parameter terhadap model. Melakukan pemeriksaan diagnostik yaitu uji asumsi residual *white noise* dan uji residual berdistribusi normal. Memilih model ARFIMA berdasarkan nilai AIC terkecil.

Keenam, membuat peramalan volume impor migas untuk 1 periode ke depan.

C. Hasil dan Pembahasan

Eksplorasi Data

Pada bagian ini dilakukan eksplorasi data volume impor migas di Indonesia pada Januari 2012 hingga 2023 sebanyak 144 data.



Gambar 1. Plot Data *Time Series* Volume Impor Migas

Berdasarkan Gambar 1. menunjukkan bahwa data volume impor migas di Indonesia terdapat gejala tidak stasioner, karena pola data mengalami fluktuasi yang tidak stabil. Untuk mengetahui apakah data sudah stasioner tidak hanya dilihat berdasarkan plot tetapi dengan melakukan uji kestasioneran data. Kemudian berdasarkan statistika deskriptif yang ditampilkan pada Tabel 1. dan diperoleh informasi sebagai berikut:

Tabel 1. Deskriptif Data

Variabel	Jumlah Data	Rata-rata	Standar Deviasi	Minimum	Maksimum
Volume Impor Migas	144	3881,89	559,204	2231,46	5063,74

Pada Tabel 1. dapat dilihat bahwa data volume impor migas di Indonesia memiliki nilai rata-rata 3881,89. Nilai standar deviasi yaitu 559,204, dengan volume impor migas terendah yaitu sebesar 2231,46 ton dan nilai volume impor migas tertinggi yaitu sebesar 5063,74 ton.

Kestasioneran Data

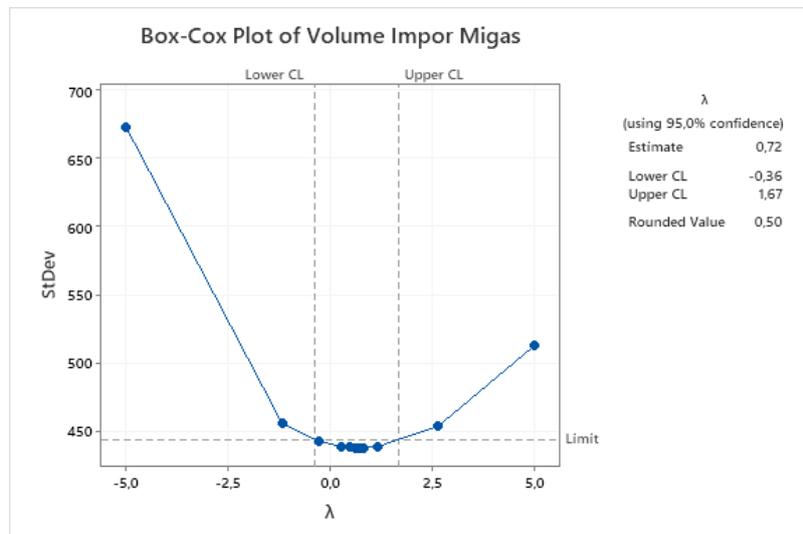
Langkah selanjutnya adalah melakukan uji kestasioneran data menggunakan uji *Augmented Dickey Fuller* (ADF).

Tabel 2. Uji Augmented Dickey Fuller

<i>p-value</i>
0,616

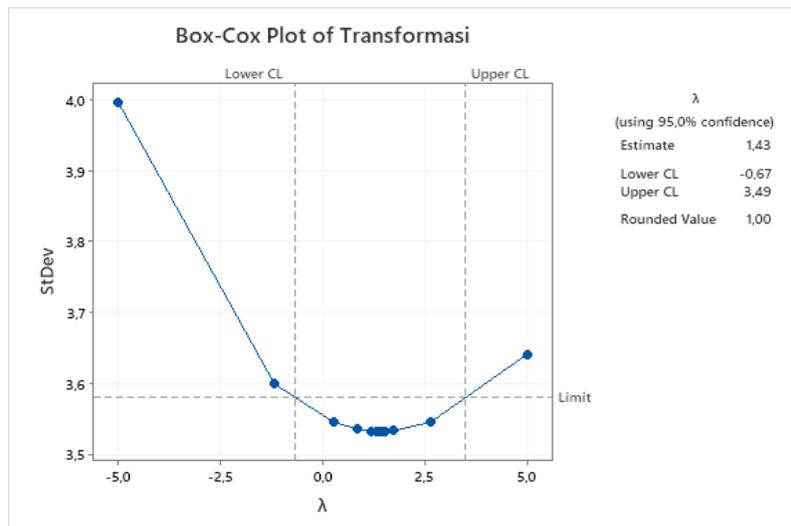
Berdasarkan Tabel 2. diperoleh bahwa p -value adalah 0,616 lebih besar dari $\alpha = 0,05$ Hal ini berarti bahwa H_0 diterima sehingga dapat disimpulkan data volume impor migas tidak stasioner.

Selanjutnya melakukan transformasi data karena data belum stasioner. Transformasi data yang digunakan yaitu Transformasi Box-Cox.



Gambar 2. Plot Box-Cox Data Volume Impor Migas

Berdasarkan Gambar 2. diperoleh bahwa *rounded value* sebesar 0,5, berdasarkan tabel Transformasi Box Cox 2.1 maka data perlu ditransformasi menggunakan transformasi $\sqrt{Z_t}$.



Gambar 3. Plot Box-Cox Setelah Transformasi

Berdasarkan Gambar 3. menunjukkan bahwa *rounded value* mencapai angka 1. Dapat disimpulkan bahwa data telah stasioner dalam varians. Setelah data telah stasioner dalam varians.

Tabel 3. Uji Augmented Dickey Fuller

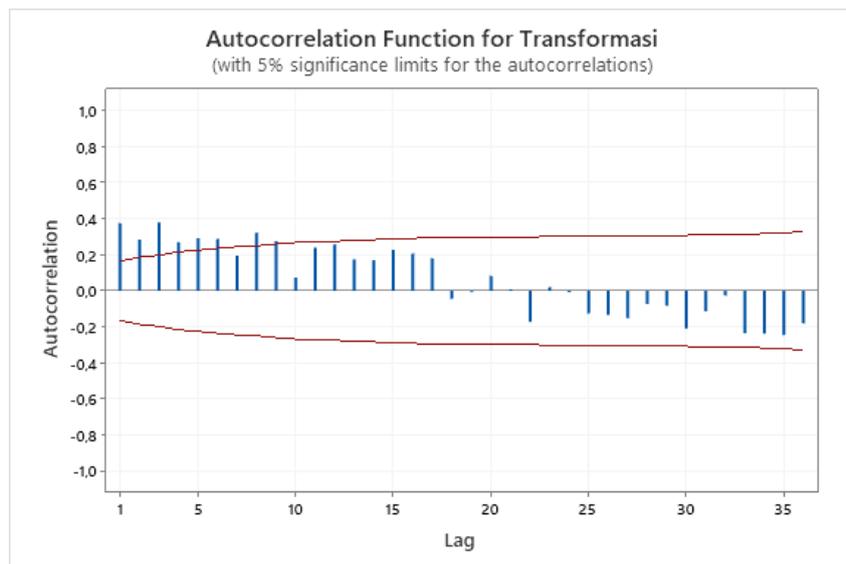
p -value
0,582

Berdasarkan Tabel 3. diperoleh bahwa p -value adalah 0,582 lebih besar dari $\alpha = 0,05$ Hal ini berarti bahwa H_0 diterima sehingga dapat disimpulkan data volume impor migas tidak stasioner.

Data yang telah di transformasi belum stasioner, langkah selanjutnya perlu dilakukan *differencing*. Tetapi pada data *short memory* proses *differencing* dilakukan dengan nilai d bilangan bulat. Sedangkan untuk data *long memory*, proses *differencing* akan dilakukan dengan nilai d bilangan pecahan yang berada diantara $0 < d < 0,5$.

Identifikasi Long Memory

Untuk mengidentifikasi jangka panjang dapat dilihat melalui plot ACF-nya dan perhitungan nilai *Hurst* (H). Jika plot ACF data turun lambat secara hiperbolik maka dapat dikatakan data deret waktu bersifat jangka panjang atau *long memory*.



Gambar 4. Plot ACF Data Setelah Transformasi

Berdasarkan Gambar 4. dapat dilihat bahwa autokorelasi menurun secara lambat atau hiperbolik namun hanya pada awalnya, yang menunjukkan potensi adanya pola jangka panjang (*long memory*). Selain melihat dari plot ACF, untuk mengidentifikasi adanya jangka panjang dapat dilakukan dengan perhitungan nilai *Hurst* (H).

Tabel 4. Nilai *Hurst*

Nilai <i>Hurst</i>
0,724

Berdasarkan Tabel 4. diperoleh nilai *Hurst* sebesar 0,724 yang berada pada rentang $0,5 < H < 1$. Hal ini menunjukkan bahwa data volume impor migas mempunyai sifat jangka panjang atau *long memory*, yang berarti bahwa pola atau tren yang muncul dalam data volume impor migas cenderung bertahan dalam jangka waktu yang lebih lama.

Pemodelan ARFIMA(p,d,q)

Dengan menggunakan *software R-Studio* diperoleh hasil perhitungan estimasi parameter pembeda, nilai parameter *differencing* ditentukan dengan metode Geweke Porter-Hudak (GPH).

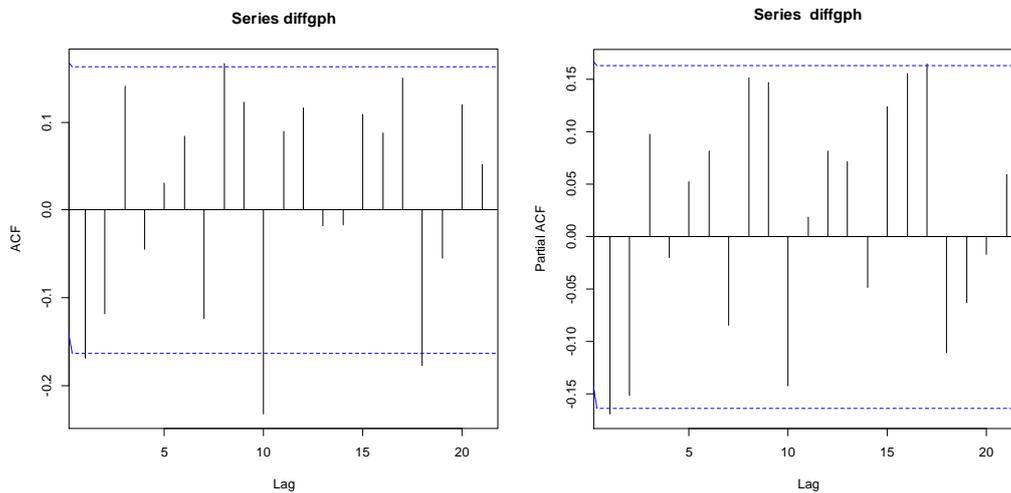
Tabel 5. Estimasi Parameter Pembeda

Estimasi Parameter Pembeda
0,421

Berdasarkan Tabel 5. hasil estimasi parameter pembeda (d) diperoleh bahwa nilai d sebesar 0,421 yang berada di antara 0 sampai 0,5. Hal ini mengindikasikan bahwa data mengikuti proses stasioner dengan fungsi autokorelasinya yang menunjukkan turun lambat atau turun secara hiperbolik menuju nol.

Identifikasi Model ARFIMA

Langkah selanjutnya adalah mengidentifikasi model ARFIMA yang dilakukan dengan mengamati hasil plot *Autocorrelatuon Function* (ACF) dan *Partial Autocorrelatuon Function* (PACF) setelah proses *differencing* (d) yang telah diestimasi menggunakan Geweke dan Porter-Hudak (GPH).



Gambar 5. Plot ACF dan PACF

Berdasarkan Gambar 5. merupakan Plot ACF dan PACF dari data yang telah di-*differencing* dengan $\hat{d}_{gph} = 0,421$. Pada Gambar 5. dapat dilihat bahwa pada plot ACF, terdapat *cut-off* pada lag ke-1, sementara pada plot PACF terdapat *cut-off* di lag ke-1. Diperoleh model yaitu ARFIMA(1,d,0), ARFIMA(0,d,1), ARFIMA(1,d,1).

Estimasi Parameter ARFIMA

Setelah mendapatkan nilai estimasi untuk parameter pembeda (d), langkah selanjutnya adalah melakukan estimasi parameter pada model ARFIMA(p,d,q). Hasil estimasi parameter p dan q dari masing-masing model ARFIMA(p,d,q) yang diperoleh berdasarkan *software R-Studio*.

Tabel 6. Estimasi Parameter ARFIMA

Model	Parameter	Estimasi Parameter	p-value
ARFIMA(1,d,0)	ϕ_1	-0,184	0,025*
ARFIMA(0,d,1)	θ_1	-0,228	0,007*
ARFIMA(1,d,1)	ϕ_1	0,135	0,596
	θ_1	0,351	0,133

Ket(*): Signifikan

Tabel 6. merupakan hasil estimasi parameter ϕ dan θ dari beberapa model yang diperoleh dengan menetapkan estimasi parameter d menggunakan metode GPH. Dapat diketahui dari uji signifikansi parameter model apabila $p\text{-value} < 0,05$, maka parameter model dinyatakan signifikan. Dari 3 model menunjukkan bahwa model ARFIMA(1,d,0), ARFIMA(0,d,1) dengan $\hat{d}_{gph} = 0,421$ memiliki parameter yang signifikan.

Pemeriksaan Diagnostik

Tahapan selanjutnya adalah melakukan pemeriksaan diagnostik, yang meliputi uji asumsi nilai residual *white noise* dan uji asumsi residual berdistribusi normal. Pengujian asumsi *white noise* bertujuan untuk mengetahui

apakah terdapat korelasi antar sisaan atau residual yang dihasilkan dari model ARFIMA yang signifikan menggunakan Ljung-Box.

Tabel 7. Pengujian *White Noise* Residual Model

Model	Uji <i>White Noise</i> (<i>p-value</i>)
ARFIMA(1,d,0)	0,7031*
ARFIMA(0,d,1)	0,8913*

Ket(*): Signifikan

Berdasarkan Tabel 7. dapat disimpulkan bahwa hasil uji autokorelasi residual dari semua model yang terpilih memiliki $p\text{-value} > \alpha = 0,05$. Oleh karena itu, H_0 diterima yang artinya tidak terdapat korelasi antar residual dalam model atau model-model tersebut telah memenuhi asumsi residual *white noise*.

Selanjutnya, uji asumsi distribusi normal dari residual dilakukan menggunakan uji Kolmogorov-Smirnov untuk mengetahui apakah residual tersebut mengikuti berdistribusi normal atau tidak.

Tabel 8. Pengujian Normalitas Residual Model

Model	D	<i>p-value</i>
ARFIMA(1,d,0)	0,046	0,634*
ARFIMA(0,d,1)	0,049	0,566*

Ket(*): Signifikan

Selanjutnya, melakukan uji normalitas berdasarkan Tabel 8. hasil dari residual semua model yang terpilih menunjukkan bahwa $p\text{-value} > \alpha = 0,05$. Sehingga H_0 diterima yang artinya residual dari model berdistribusi normal. Maka dapat disimpulkan bahwa asumsi residual *white noise* dan normalitas telah terpenuhi.

Pemilihan Model Terbaik

Proses pemilihan model ARFIMA dilakukan dengan mempertimbangkan kriteria nilai Akaike's Information Criterion (AIC) terkecil. Nilai AIC dari model ARFIMA untuk data volume impor migas disajikan pada Tabel 9. sebagai berikut.

Tabel 9. Nilai AIC

Model	AIC
ARFIMA(1,d,0)	1796,71
ARFIMA(0,d,1)	1795,294

Tabel 9. menunjukkan bahwa model ARFIMA yang terpilih dengan $\hat{d}_{gph} = 0,421$ adalah diperoleh model ARFIMA(0,d,1) dengan nilai AIC terkecil yaitu 1795,294.

Model terbaik akan digunakan untuk meramalkan Volume Impor Migas. Persamaan model ARFIMA(0,d,1) dengan $\hat{d}_{gph} = 0,421$ adalah sebagai berikut:

$$\phi_p(B)(1 - B)^d Z_t^* = \theta_q(B)e_t$$

$$\phi_p(B)(1 - B)^d Z_t^* = (1 - \theta_1 B)e_t$$

$$\phi_p(B)(1 - B)^d Z_t^* = 1 - \theta_1 e_{t-1}$$

$$(1 - B)^{0,421} Z_t^* = e_t + 0,228e_{t-1}$$

Nilai $(1 - B)^{0,421}$ menggambarkan memori jangka panjang dalam deret waktu. Jika $(1 - B)^{0,421}$ dimisalkan sebagai W_t yang menunjukkan memori jangka panjang, maka:

$$W_t Z_t^* = e_t + 0,228e_{t-1}$$

dengan $(1 - B)^{0,421}$ dijabarkan sebagai:

$$(1 - B)^{0,421} = 1 - 0,421B - \frac{1}{2}(0,421)B^2 - \frac{1}{6}(0,421)B^3$$

$$(1 - B)^{0,421} = 1 - 0,421B - 0,210B^2 - 0,070B^3$$

Model ARFIMA(0,d,1) dijabarkan sebagai berikut:

$$W_t Z_t^* = e_t + 0,228e_{t-1}$$

$$(1 - 0,421B - 0,210B^2 - 0,070B^3)Z_t^* = e_t + 0,228e_{t-1}$$

$$Z_t^* - 0,421Z_{t-1}^* - 0,210Z_{t-2}^* - 0,070Z_{t-3}^* = e_t + 0,228e_{t-1}$$

$$Z_t^* = 0,421Z_{t-1}^* + 0,210Z_{t-2}^* + 0,070Z_{t-3}^* + e_t + 0,228e_{t-1}$$

Dengan, $Z_t^* = \sqrt{Z_t}$, Z_t^* merupakan data volume impor migas setelah transformasi.

Peramalan

Setelah diperoleh model ARFIMA terbaik untuk data volume impor migas, yaitu model ARFIMA(0;0,421;1). Selanjutnya yaitu melakukan peramalan, berikut hasil peramalan volume impor migas pada Bulan Januari 2024 dapat dilihat pada Tabel 10.

Tabel 10. Hasil Peramalan Volume Impor Migas

No	Waktu	Volume Impor Migas
145	Januari 2024	4413,147

D. Kesimpulan

Berdasarkan hasil analisis yang telah dilakukan, diperoleh kesimpulan bahwa hasil estimasi parameter pembeda (d) pada model ARFIMA untuk data Volume Impor Migas dengan menggunakan metode Geweke and Porter-Hudak (GPH) terbaik yang diperoleh yaitu $\hat{d}_{gph} = 0,421$. Model terbaik adalah ARFIMA(0;0,421;1) dengan nilai AIC 1795,294 diperoleh model sebagai berikut:

$$Z_t^* = 0,421Z_{t-1}^* + 0,210Z_{t-2}^* + 0,070Z_{t-3}^* + e_t + 0,228e_{t-1}$$

Daftar Pustaka

- [1] M. I. Wiladibrata and N. A. K. Rifai, "Peramalan Produksi Mobil Menggunakan Metode Double Exponential Smoothing dengan Algoritma Golden Section," *Bandung Conference Series: Statistics*, vol. 2, no. 2, pp. 507–511, Aug. 2022, doi: 10.29313/bcss.v2i2.4776.
- [2] D. C. Montgomery, C. L. Jennings, and M. Kulahci, *Introduction To Time Series Analysis And Forecasting*. Canada: John Wiley And Sons, Inc, 2015.
- [3] U. N. Fazrilillah and O. Rohaeni, "Penerapan Metode Holt's Exponential Smoothing Dalam Memprediksi Jumlah Nasabah Kredit," *DataMath: Journal of Statistics and Mathematics*, vol. 2, no. 1, pp. 11–16, 2024.
- [4] S. Pratiwi and M. Herlina, "Pengaruh Harga Pangan terhadap Inflasi dengan Metode Vector Autoregressive Integrated Moving Average," *Jurnal Riset Statistika*, vol. 3, no. 2, pp. 87–96, Dec. 2023, doi: 10.29313/jrs.v3i2.2690.
- [5] P. Paridi, "Perbandingan Metode ARIMA (Box Jenkins), ARFIMA, Regresi Spektral dan SSA dalam Peramalan Jumlah Kasus Demam Berdarah Dengue di Rumah Sakit Hasan Sadikin Bandung," *JISIP (Jurnal Ilmu Sosial dan Pendidikan)*, vol. 3, no. 1, Mar. 2019, doi: 10.58258/jisip.v3i1.707.
- [6] J. R. M. Hosking, "Fractional differencing," *Biometrika*, vol. 68, no. 1, pp. 165–176, 1981, doi: 10.1093/biomet/68.1.165.
- [7] G. Darmawan, "Pemodelan ARFIMA Nonstasioner Melalui Metode Modifikasi GPH (Geweke and Porter Hudak)," Pustaka Ilmiah Universitas Padjajaran.

- [8] P. Kartikasari, H. Yasin, and D. A. I. Maruddani, “Autoregressive Fractional Integrated Moving Average (ARFIMA) Model to Predict Covid-19 Pandemic Cases in Indonesia,” *Media Statistika*, vol. 14, no. 1, pp. 44–55, Jun. 2021, doi: 10.14710/medstat.14.1.44-55.
- [9] Haryadi, *Ekonomi Internasional: Teori dan Aplikasi*. Bogor: Biografika, 2013.
- [10] E. Christianto, “Faktor yang Mempengaruhi Volume Impor Beras di Indonesia ,” *Jurnal JIBEKA*, vol. 7, no. 2, pp. 38–43, Aug. 2013.
- [11] V. B. Kusnandar, “Defisit Perdagangan Migas Indonesia Makin Besar pada 2022,” databoks. Accessed: Jul. 18, 2024. [Online]. Available: <https://databoks.katadata.co.id/datapublish/2023/02/06/defisit-perdagangan-migas-indonesia-makin-besar-pada-2022>
- [12] W. W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*, 2nd Edition. United States of America: Pearson Addison Wesley, 2006.