



Peramalan Tingkat Inflasi di Indonesia dengan Metode ARIMA-GARCH Berdasarkan Optimasi Kalman Filter

Nuraeni Intan¹, M. Al Haris², Prizka Rismawati Arum³

^{1,2,3}Program Studi Statistika, Universitas Muhammadiyah Semarang

¹nuraeniintanr1001@gmail.com

²alharis@unimus.ac.id

³prizka.rismawatiarum@unimus.ac.id

Corresponding author email: alharis@unimus.ac.id

Abstract: Forecasting inflation rates is a crucial aspect of economic analysis influenced by price volatility. This volatility occurs when prices fluctuate, leading to non-constant data variance and resulting in a violation of the homoscedasticity assumption (heteroscedasticity) in inflation forecasting. Violating this assumption can cause bias in model estimation. To address the heteroscedasticity issue, this study employs the Autoregressive Integrated Moving Average (ARIMA) Generalized Autoregressive Conditional Heteroscedasticity (GARCH) model. This method can model and forecast the variance of residuals that are not constant in the data. To further optimize the model, this study integrates the Kalman Filter as a technique to minimize error covariance. The data used in this study is the inflation rate data of Indonesia from January 2010 to December 2023. Based on the analysis results, the presence of heteroscedasticity in Indonesia's inflation rate data is detected in the residuals. The best model obtained is the ARIMA(0,1,1)-GARCH(1,1) model. The application of the Kalman Filter in this method improves the estimation results, as indicated by the MAPE value of the ARIMA(0,1,1)-GARCH-Kalman Filter polynomial degree 2 at 3.60%, compared to the ARIMA(0,1,1)-GARCH(1,1) model at 12.42%. The forecasted average inflation rate for Indonesia for the next six periods ranges between 2% and 3%.

Keywords: ARCH-GARCH, Forecasting, Inflation, Kalman Filter

Abstrak: Peramalan tingkat inflasi merupakan aspek penting dalam analisis ekonomi yang dipengaruhi oleh volatilitas harga. Volatilitas ini terjadi ketika harga-harga mengalami perubahan yang fluktuatif, hal ini akan mengakibatkan variansi data menjadi tidak konstan dan akan berdampak pada pelanggaran asumsi kehomogenan ragam (heterokedastisitas) dalam peramalan inflasi. Pelanggaran terhadap asumsi ini dapat menyebabkan bias dalam estimasi model peramalan. Untuk mengatasi masalah heterokedastisitas tersebut, dalam penelitian ini digunakan model *Autoregressive Integrated Moving Average* (ARIMA) *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Metode ini dapat memodelkan dan meramalkan ragam dari residual model yang tidak konstan dalam data. Guna lebih mengoptimalkan model, dalam penelitian ini penulis akan mengintegrasikan Kalman Filter sebagai teknik untuk meminimalkan kovarian *error*. Data yang digunakan dalam penelitian ini adalah data tingkat inflasi Indonesia periode Januari 2010 sampai dengan Desember 2023. Berdasarkan hasil analisis, data tingkat inflasi Indonesia terdeteksi adanya heteroskedastisitas pada sisaan residual. Model terbaik yang didapatkan adalah model ARIMA(0,1,1)-GARCH(1,1). Penerapan Kalman Filter pada metode ini mampu memperbaiki hasil estimasi yang ditandai dengan nilai MAPE ARIMA(0,1,1)-GARCH-Kalman Filter polinomial derajat 2 sebesar 3,60% lebih kecil dibandingkan dengan Model ARIMA(0,1,1)-GARCH(1,1) sebesar 12,42%. Hasil ramalan yang didapatkan untuk rata-rata tingkat inflasi Indonesia untuk 6 periode kedepan berkisar di 2% hingga 3%.

Kata kunci: ARIMA-GARCH, Inflasi, Kalman Filter, Peramalan

I. PENDAHULUAN

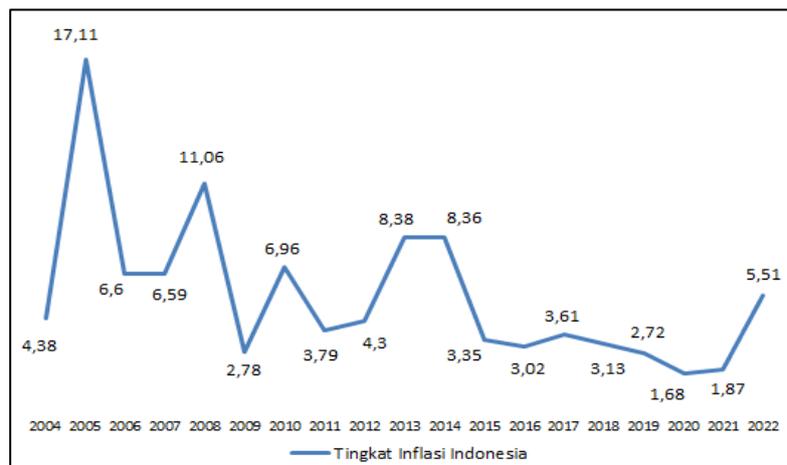
Fenomena ekonomi inflasi merupakan isu yang menjadi perhatian serius di seluruh dunia, termasuk di Indonesia, karena inflasi memegang peranan penting dalam menjaga stabilitas ekonomi suatu negara [1]. Inflasi adalah suatu keadaan di mana terjadi peningkatan harga secara umum untuk barang dan jasa dalam perekonomian. Saat tingkat inflasi meningkat, dampak yang langsung terlihat adalah kenaikan harga barang dan jasa secara menyeluruh [2].

Indonesia pernah mengalami hiperinflasi (635,5%) pada 1963-1965 dan inflasi tinggi (77,5%) di 1998. Kenaikan ini menyebabkan krisis ekonomi dan hilangnya kepercayaan masyarakat terhadap mata uang. Namun, inflasi yang terlalu rendah juga berbahaya. Inflasi rendah yang lama menandakan



ekonomi di bawah potensinya, yang dapat menyebabkan perlambatan pertumbuhan ekonomi dan membatasi kebijakan moneter untuk membantu ekonomi [3].

Berdasarkan data yang tercatat dari Bank Indonesia, tingkat inflasi Indonesia terus mengalami fluktuasi dari tahun 2004 hingga 2022. Tingkat inflasi tertinggi terjadi pada tahun 2005 mencapai 17,11%, dan yang terendah terjadi pada tahun 2020 sebesar 1,68%. Informasi tentang tingkat inflasi di Indonesia dapat dilihat pada Gambar 1.1.



Gambar 1. Tingkat inflasi Indonesia tahun 2004 – 2022

Gambar 1 menunjukkan bahwa tingkat inflasi di Indonesia pada tahun 2004 hingga 2005 terjadi kenaikan yang signifikan, yaitu mencapai 12,73% kemudian terjadi penurunan pada tahun 2006 mencapai 10,51%. Pada tahun 2012 hingga 2013, kembali terjadi kenaikan sebesar 4,06%. Kemudian tahun 2014 hingga 2015, tercatat kembali terjadi penurunan sebesar 5,01%. Terakhir, pada tahun 2021 hingga 2022, kembali terjadi kenaikan sebesar 3,64%. Menurut laporan Badan Pusat Statistik (BPS), inflasi tahun 2022 sebesar 5,51% menjadi rekor inflasi tertinggi dalam 8 tahun terakhir melampaui target sasaran Bank Indonesia yang diperkirakan sekitar 2-4% [4].

Inflasi bukan hanya gejala kenaikan harga, tetapi memiliki dampak besar pada perekonomian dan kesejahteraan masyarakat. Oleh karena itu, penting untuk melakukan analisis, prediksi, dan tindakan untuk menjaga agar inflasi tidak naik terlalu tinggi atau terlalu rendah. Hal ini dapat dilakukan dengan forecasting atau peramalan [5].

Metode peramalan populer yang umum digunakan adalah metode *Autoregressive Integrated Moving Average* (ARIMA) dikembangkan oleh Box dan Jenkins [6], [7]. Model ARIMA ini memiliki asumsi penting yang harus dipenuhi seperti parameter yang signifikan, residual yang bersifat white noise, serta berdistribusi normal. Namun, pada data finansial seperti inflasi, harga saham, dan kurs mata uang, sering kali terjadi volatilitas yang menyebabkan ragam sisaan tidak homogen. Ketidak-homogenan ragam sisaan ini dapat menyebabkan estimasi parameter dalam model menjadi tidak valid [8].

Untuk mengatasi ketidak-homogenan ragam sisaan dalam data finansial tersebut, digunakan metode pemodelan ragam sisaan yaitu model *Autoregressive Conditional Heteroscedasticity* (ARCH) dan *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) untuk mengatasi masalah heteroskedastisitas dalam data deret waktu [9]. Guna lebih mengoptimalkan model, dalam penelitian ini penulis akan mengintegrasikan Kalman Filter sebagai teknik untuk meminimalkan kovarian *error* [10]. Kalman Filter pertamakali diperkenalkan oleh R.E Kalman pada tahun 1960. Metode ini dirancang



untuk meminimalkan kovarian kesalahan estimasi, sehingga memungkinkan untuk menghasilkan estimasi yang optimal dari variabel keadaan dalam suatu sistem berdasarkan pengamatan yang tersedia [11].

Penelitian tentang model ARCH-GARCH menggunakan Kalman Filter telah dilakukan oleh Lusi Nur Rahmawati, Mardijah, dan Amirul Hakam mengenai penerapan metode Kalman Filter dalam estimasi harga saham menggunakan model ARCH-GARCH. Hasil penelitian ini diperoleh MAPE yang dihasilkan dari penggunaan Metode *Kalman Filter* lebih rendah yaitu sebesar 0,89% dibandingkan dengan MAPE yang diperoleh dari model GARCH (1,1) yaitu sebesar 1,21% [10]. Penelitian yang dilakukan oleh Ridho Sholehurrohman, Mochammad Reza Habibi dkk. tentang analisis metode Kalman Filter, *Particle Filter*, dan *Correlation Filter* untuk Pelacakan Objek. Hasil penelitian ini menunjukkan bahwa persentase akurasi dari hasil kalkulasi *tracking* objek dan analisis metode menunjukkan Kalman Filter mendapatkan 96,89%, dimana optimasi tersebut lebih baik dibandingkan kedua optimasi lainnya [12]. Berdasarkan latar belakang di atas, penulis merasa tertarik untuk melakukan penelitian tentang peramalan tingkat inflasi di Indonesia dengan metode ARCH-GARCH berdasarkan optimasi Kalman Filter.

II. METODE PENELITIAN

2.1. Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder mengenai data bulanan inflasi di Indonesia. Rentang waktu pengamatan data ini dimulai dari bulan Januari 2010 hingga bulan Desember 2023. Keseluruhan dataset terdiri dari 168 pengamatan yang diperoleh dari *website* Bank Indonesia Data Inflasi (bi.go.id) [2].

2.2. Langkah-langkah Penelitian

Langkah-langkah analisis menggunakan metode ARIMA-GARCH dengan Kalman Filter untuk peramalan meliputi tahapan-tahapan berikut [7], [13], [14]:

1. Melakukan analisis deskriptif dengan tujuan untuk memahami karakteristik dasar dari data yang sedang digunakan.
2. Membagi data menjadi dua bagian, yakni data latihan (*training*) dan data uji (*testing*). Dalam penelitian ini, data *training* akan mencakup 75% (126 observasi), sementara data *testing* akan mencakup 25% (42 observasi).
3. Melakukan pemeriksaan kestasioneran data terhadap variansi dan rata-rata. Apabila data menunjukkan ketidakstasioneran terhadap variansi, maka diperlukan transformasi. Sedangkan apabila data tidak stasioner terhadap rata-rata, maka perlu dilakukan *differencing*.
4. Mengidentifikasi model ARIMA yang tepat dengan menganalisis plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) untuk menentukan nilai-nilai ordo p dan q yang sesuai dalam model ARIMA.
5. Melakukan estimasi parameter dengan menggunakan metode *Maximum Likelihood* untuk beberapa model yang mungkin kemudian, melakukan uji signifikansi parameter.
6. Memilih model ARIMA terbaik berdasarkan nilai AIC terkecil.
7. Melakukan uji diagnostik yang mencakup uji *white noise*, dan uji normalitas.
8. Melakukan uji *Lagrange Multiplier* (LM) pada model terbaik yang telah diidentifikasi dari Model ARIMA. Uji ini bertujuan untuk memeriksa apakah ada tanda-tanda heterokedastisitas pada sisaan dari model.



9. Mengidentifikasi model ragam sisaan ARCH-GARCH, kemudian melakukan estimasi parameter dengan metode *Maximum Likelihood* dan uji signifikansi paramter.
10. Melakukan pemilihan model terbaik berdasarkan nilai AIC terkecil kemudian melakukan uji diagnostik pada model ARCH-GARCH, meliputi, uji normalitas, uji *white noise*, dan uji ARCH-LM serta mengevaluasi akurasi model dengan memeriksa nilai MAPE
11. Melakukan peramalan untuk 6 periode (bulan) ke depan menggunakan model ARCH-GARCH terbaik.
12. Mengimplementasikan Kalman Filter polinomial derajat 1 dan polinomial derajat 2 sebagai perbaikan *error* dari hasil ramalan data tingkat Inflasi Indonesia pada model ARCH-GARCH.
13. Melakukan perbandingan hasil akurasi *Mean Absolute Percentage Error* (MAPE) model ARIMA-GARCH dan ARIMA-GARCH Kalman Filter.
14. Melakukan peramalan untuk 6 periode (bulan) ke depan dengan menggunakan model terbaik.

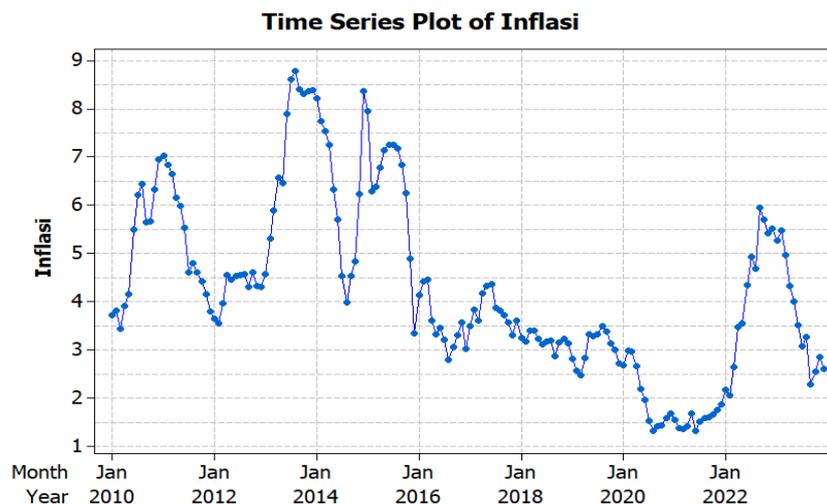
III. HASIL DAN PEMBAHASAN

Analisis deskriptif digunakan untuk mengetahui informasi-informasi umum mengenai data tingkat inflasi Indonesia. Deskriptif statistik data tingkat inflasi Indonesia dari bulan Januari 2010 hingga bulan Desember 2023 dapat dilihat pada Tabel 1.

Tabel 1. Contoh tabel

Variabel	N	Min	Mean	Median	Max
Inflasi	168	1,32	3,85	4,25	8,79

Berdasarkan Tabel 1, dapat dilihat bahwa rata-rata tingkat inflasi Indonesia dalam kurun waktu 14 tahun terakhir sebesar 3,85 perbulan, tingkat inflasi terendah sebesar 1,32 sedangkan inflasi tertinggi sebesar 8,79 dengan nilai median sebesar 4,25. Untuk mengetahui perubahan tingkat inflasi tersebut, dapat dilihat pada Gambar 2.



Gambar 2. Plot Data Bulanan Inflasi Indonesia

Berdasarkan Gambar 2 dapat diketahui bahwa data tingkat inflasi Indonesia tertinggi terjadi pada bulan agustus 2013 sebesar 8,79%. Sedangkan tingkat inflasi terendah terjadi pada bulan agustus 2020 sebesar 1,32%. Dapat dilihat pada grafik bahwa data tingkat inflasi Indonesia mengandung unsur trend yang artinya data tersebut tidak stasioner dalam varians maupun rataan. Hal ini dapat terlihat adanya



gejala volatilitas pada data yang menunjukkan mengalami kenaikan dan juga penurunan. Oleh karena itu dapat dilakukan uji stasioneritas terlebih dahulu.

3.1. Uji Kestasioneran Data

Uji kestasioneran data dilakukan dengan memeriksa kestasioneran dalam varians dan rata-rata. Stasioner dalam variansi merujuk pada sifat suatu deret waktu dimana variansnya tetap konstan sepanjang waktu. Untuk melakukan pengecekan ini, menggunakan nilai λ dari analisis Box-Cox. Data dikatakan stasioner dalam varians jika nilai $\lambda = 1$. Apabila data tidak stasioner perlu dilakukan transformasi data. Hasil transformasi *Box-Cox Test* disajikan pada Tabel 2.

Tabel 2. Uji *Box-Cox Test*

Data	Nilai λ	Keterangan
Sebelum Transformasi	-0,548	Tidak stasioner
Setelah Transformasi	1	Stasioner

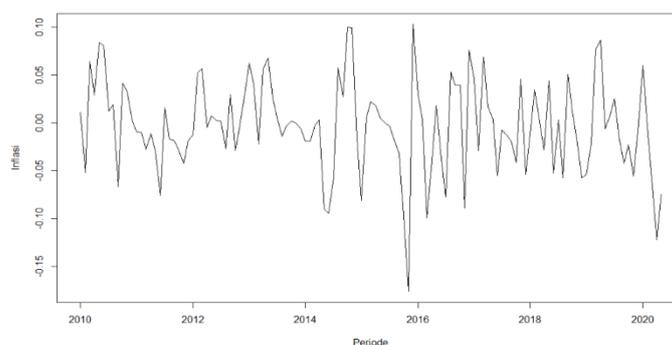
Tabel 2 menunjukkan bahwa sebelum dilakukan transformasi diperoleh nilai *rounded value* sebesar $-0,548 < 1$ yang artinya bahwa data belum stasioner dalam varians, sehingga perlu dilakukan transformasi. Setelah dilakukan transformasi data dengan persamaan $1/\sqrt{Z}$, diperoleh nilai *rounded value* sebesar 1 yang artinya bahwa data telah stasioner dalam varians.

Selanjutnya data deret waktu dianggap stasioner dalam rata-rata jika fluktuasi datanya tidak mengalami perubahan signifikan seiring berjalannya waktu dan tetap berada dalam kisaran nilai rata-rata yang konstan. Untuk melakukan pengecekan ini, dapat digunakan nilai uji *Augmented Dickey-Fuller*. Data dikatakan stasioner dalam rata-rata apabila nilai *p-value* $< (0,05)$, maka hipotesis H_0 ditolak atau data sudah stasioner terhadap rata-rata. Namun, apabila hasil uji menunjukkan bahwa data belum stasioner terhadap rata-rata, maka diperlukan proses *differencing*. Hasil statistik uji *Augmented Dickey-Fuller* disajikan pada Tabel 3.

Tabel 3. Uji *Augmented Dickey-Fuller (ADF)*

Data	<i>P-value</i>	Keterangan
Sebelum <i>differencing</i>	0,318	Tidak stasioner
Setelah <i>differencing</i>	0,01	Stasioner

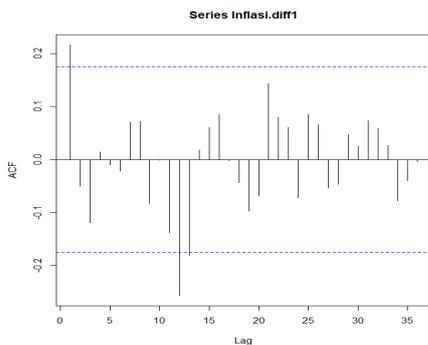
Tabel 3 menunjukkan bahwa sebelum dilakukan *differencing*, diperoleh nilai *p-value* sebesar 0,318 $> (0,05)$ yang menunjukkan bahwa data belum stasioner dalam rata-rata. Kemudian setelah dilakukan *differencing* diperoleh nilai *p-value* sebesar 0,01 $< (0,05)$ yang menunjukkan bahwa data telah stasioner dalam rata-rata, hal ini juga dapat ditunjukkan dalam plot yang disajikan pada Gambar 3.



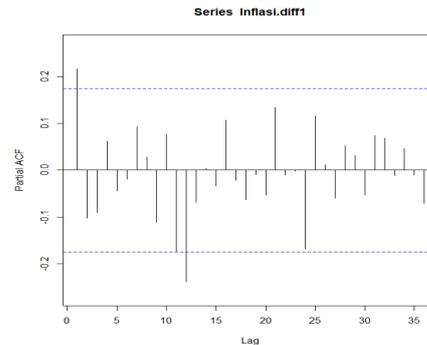
Gambar 3. Plot data bulanan inflasi Indonesia setelah stasioner dalam rata-rata

3.2. Identifikasi Model

Setelah data telah memenuhi asumsi kestasioneran, langkah selanjutnya adalah melakukan identifikasi model ARIMA berdasarkan plot ACF dan PACF untuk mengidentifikasi atau menetapkan model sementara yang tepat. Plot ACF dan PACF disajikan pada Gambar 4.



Gambar 4a. Plot ACF data bulanan inflasi Indonesia



Gambar 4b. Plot PACF data bulanan inflasi Indonesia

Gambar 4. Plot Plot ACF dan PACF data bulanan inflasi Indonesia

Berdasarkan Gambar 4, dapat dilihat bahwa Plot ACF data bulanan inflasi Indonesia terpotong setelah lag ke-1, maka perkiraan ordo q maksimum pada ARIMA (p,d,q) adalah 1. Sedangkan pada plot PACF juga terpotong setelah lag ke-1, maka perkiraan ordo p maksimum pada ARIMA (p,d,q) adalah 1, dan dikarenakan dilakukan *differencing* satu kali, maka d bernilai 1. Dengan demikian diperoleh model-model dugaan yang sesuai untuk data Inflasi tersebut adalah model ARIMA $(0, 1, 1)$, ARIMA $(1, 1, 0)$ dan ARIMA $(1, 1, 1)$.

3.3. Estimasi Parameter dan Uji Signifikansi

Setelah menetapkan model sementara dari hasil identifikasi, langkah berikutnya adalah melakukan penaksiran parameter dan uji signifikansi parameter. Hasil penaksiran dan pengujian parameter model disajikan pada Tabel 4.

Tabel 4. Hasil estimasi parameter dan uji signifikansi

Model	Parameter	Estimasi	SE	P-value	Signifikan	AIC
ARIMA (0, 1, 1)	MA(1)	0,3889	0,0794	< 0,000	Signifikan	187,854
ARIMA (1, 1, 0)	AR(1)	0,3293	0,0840	< 0,000	Signifikan	191,330
ARIMA (1, 1, 1)	AR(1)	0,0157	0,1972	0,9362	Tidak	189,846
	MA(1)	0,3764	0,1777	0,0341	Signifikan	

Tabel 4 menunjukkan bahwa model ARIMA $(0,1,1)$ dan ARIMA $(1,1,0)$ masing-masing memiliki nilai parameter yang signifikan dengan ditunjukkan nilai p -value yang dihasilkan sebesar $(0,000) < (0,05)$. Akan tetapi, model ARIMA $(1,1,1)$ memiliki nilai p -value untuk parameter AR sebesar $0,9362 > (0,05)$ yang menunjukkan bahwa parameter tersebut tidak signifikan. Sehingga model yang layak digunakan antara model ARIMA $(0,1,1)$ dan ARIMA $(1,1,0)$ adalah dengan melihat nilai AIC terkecil yaitu model ARIMA $(0,1,1)$.

3.4. Diagnostik Model

Tujuan dari uji diagnostik ini adalah untuk mengevaluasi sejauh mana model yang telah dipilih mampu dengan akurat menjelaskan data residual kuadrat dari model rata-rata. Proses uji diagnostik dapat dilakukan dengan uji *white noise* dan uji distribusi normal. Hasil pengujian disajikan pada Tabel 5.



Tabel 5. Uji Diagnostik Model

Uji Asumsi	P-value	Keterangan
White Noise	0,9544	White Noise
Normalitas	0,0003	Tidak berdistribusi normal

Tabel 5 menunjukkan bahwa diperoleh nilai p -value pada uji asumsi *white noise* sebesar $0,9544 > (0,05)$ yang menunjukkan model tersebut memenuhi asumsi *white noise*. Selanjutnya, pengujian normalitas diperoleh nilai p -value sebesar $0,0003 < (0,05)$ yang menunjukkan model tersebut tidak memenuhi asumsi normalitas. Menurut [15], ketidaknormalan dari residual dapat mengindikasikan kondisi heterokedastisitas pada varians model ARIMA terbaik. Sehingga analisis lebih lanjut dilakukan pemodelan ARCH-GARCH.

3.5. Pengujian Efek Heterokedastisitas

Identifikasi adanya efek ARCH pada sisaan model ARIMA (0,1,1) dapat dilakukan dengan menggunakan uji *Lagrange Multiplier* (LM). Jika nilai p -value $< \alpha$ (0,05), menunjukkan adanya heterokedastisitas pada model. Hasil uji ARCH-LM pada sisaan model ARIMA (0,1,1) ditunjukkan pada Tabel 6.

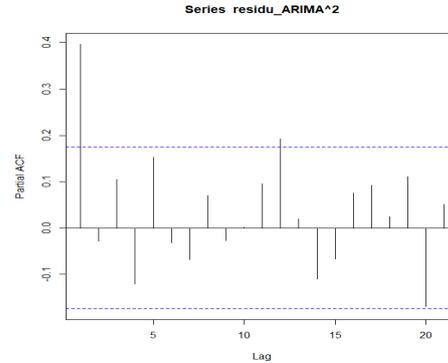
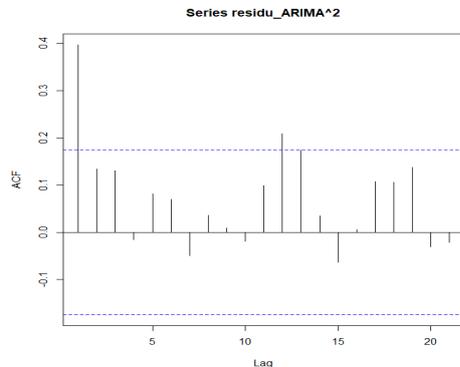
Tabel 6. Uji ARCH-LM lag ke-1 sampai ke-15

Lag	P-value	Lag	P-value	Lag	P-value
1	< 0,000	6	0,0002	11	0,0059
2	< 0,000	7	0,0006	12	0,0009
3	0,0001	8	0,0011	13	0,0018
4	0,0001	9	0,0022	14	0,0018
5	0,0001	10	0,0001	15	0,0030

Tabel 6 menunjukkan bahwa nilai p -value dari lag ke-1 sampai lag ke-12 lebih kecil dari (0,05), maka keputusan yang diambil adalah Tolak H_0 atau dapat disimpulkan bahwa terdapat unsur heteroskedastisitas pada sisaan model ARIMA (0,1,1). Kondisi yang menolak H_0 ini terjadi sampai dengan lag ke-15, sehingga dapat dikatakan bahwa terdapat indikasi bahwa pemodelan ini lebih cocok menggunakan model GARCH dibandingkan model ARCH. Hal tersebut bersesuaian dengan pernyataan [16], yang menyebutkan bahwa ketika pemeriksaan sisaan yang dilakukan menghasilkan lag 1 sampai 12 signifikan, maka model ARCH lebih cocok digunakan. Namun jika pemeriksaan sisaan dilakukan hingga lebih dari lag 12 signifikan, maka model GARCH lebih cocok digunakan. Oleh karena itu, selanjutnya akan dilakukan pendugaan model menggunakan model GARCH.

3.6. Identifikasi Model GARCH

Langkah awal yang dilakukan dalam pemodelan GARCH adalah membuat plot ACF dan PACF dari residual kuadrat model ARIMA (0,1,1) untuk mengidentifikasi atau menetapkan model GARCH yang sesuai. plot ACF dan PACF dari residual kuadrat model ARIMA (0,1,1) ditunjukkan pada Gambar 5. Berdasarkan Gambar 5 dapat dilihat bahwa plot ACF dan PACF kuadrat residual model ARIMA (0,1,1) masing-masing menunjukkan terdapat dua batang atau lag yang keluar dari batas garis putus-putus (garis signifikan). Sehingga estimasi model yang akan bangkitkan dari plot ACF dan PACF adalah model GARCH (p, q) dengan $p = 1$ dan 2 serta $q = 1$ dan 2 . Dengan demikian diperoleh model-model dugaan yang sesuai berdasarkan plot ACF dan PACF adalah GARCH (1,1), GARCH (1,2), GARCH (2,1) dan GARCH (2,2).



Gambar 5a. Plot ACF residual model ARIMA (0,1,1)

Gambar 5b. Plot PACF residual model ARIMA (0,1,1)

Gambar 5. Plot ACF dan PACF residual model ARIMA (0,1,1)

3.7. Estimasi Parameter dan Uji Signifikansi Model GARCH

Setelah menetapkan model sementara dari hasil identifikasi, langkah berikutnya adalah melakukan penaksiran parameter dan uji signifikansi parameter. Hasil penaksiran dan uji signifikansi parameter disajikan pada Tabel 7.

Tabel 7. Hasil Estimasi Parameter dan Uji Signifikansi

Model	Parameter	Estimasi	P-value	Keterangan	AIC
GARCH (1,1)	α_0	0,0007	0,0212	Signifikan	-3.2675
	α_1	0,4213	0,0133	Signifikan	
	β_1	0,3268	0,0270	Signifikan	
GARCH (1,2)	α_0	0,0008	0,0203	Signifikan	-3.2646
	α_1	0,4438	0,0103	Signifikan	
	β_1	0,0309	0,8783	Tidak Signifikan	
	β_2	0,1997	0,2393	Tidak Signifikan	
GARCH (2,1)	α_0	0,0006	0,0429	Signifikan	-3.2534
	α_1	0,4197	0,0125	Signifikan	
	α_2	0,0001	1,0000	Tidak Signifikan	
	β_1	0,3301	0,2006	Tidak Signifikan	
GARCH (2,2)	α_0	0,0008	0,0654	Tidak Signifikan	-3.2486
	α_1	0,4438	0,0112	Signifikan	
	α_2	0,0000	1,0000	Tidak Signifikan	
	β_1	0,3080	0,9398	Tidak Signifikan	
	β_2	0,1997	0,2414	Tidak Signifikan	

Tabel 7 menunjukkan bahwa model GARCH (1,1) memiliki nilai parameter yang signifikan dengan nilai p -value yang dihasilkan sebesar (0,0133) dan (0,0270) < (0,05), sedangkan model GARCH (1,2), GARCH (2,1) dan GARCH (2,2) masing-masing nilai p -value yang dihasilkan > (0,05) yang menunjukkan bahwa ketiga model tersebut tidak signifikan. Sehingga model yang layak digunakan adalah model GARCH (1,1). Persamaan yang dihasilkan dari model GARCH (1,1) adalah sebagai berikut:

$$\sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

$$\sigma_t^2 = 0,0007 + 0,4213 e_{t-1}^2 + 0,3268 \sigma_{t-1}^2$$

3.8. Diagnostik Model

Diagnostik model dilakukan untuk melihat apakah model hasil estimasi diatas telah cukup baik untuk memodelkan data atau tidak dengan dilakukan beberapa uji statistik. Hasil diagnostik model disajikan pada Tabel 8.



Tabel 8. Uji Diagnostik Model GARCH (1,1)

<i>Standardised Residual Tests:</i>				
			<i>Statistic</i>	<i>P-value</i>
Jarque-Bera Test	R	Chi ²	1,5725898	0,45552946
Shapiro-Wil Test	R	W	0,9869811	0,27975126
Ljung-Box Test	R	Q(10)	9,2559656	0,50799615
Ljung-Box Test	R	Q(15)	27,7392517	0,20325940
Ljung-Box Test	R	Q(20)	30,0481352	0,06907744
Ljung-Box Test	R ²	Q(10)	12,0231908	0,20350743
Ljung-Box Test	R ²	Q(15)	21,7977755	0,11321714
Ljung-Box Test	R ²	Q(20)	32,4418133	0,30881214
LM Arch-Test	R	TR ²	15,1851186	0,23146864

Berdasarkan tabel 8 dapat dilihat diperoleh nilai *p-value* dari uji Jarque-Bera sebesar $0,4555 > (0,05)$ yang artinya bahwa model GARCH (1,1) memiliki residual berdistribusi normal. Uji Ljung-Box Test R dan Ljung-Box Text R² diperoleh nilai *p-value* pada masing masing lag $> (0,05)$ yang berarti tidak terdapat korelasi serial dalam residual kuadrat serta untuk uji ARCH-LM diperoleh nilai *p-value* sebesar $0,2314 > (0,05)$. Oleh karena itu dapat disimpulkan model tersebut sudah tidak mengandung efek ARCH/GARCH, sehingga dapat dikatakan tidak terdapat gejala heterokedastisitas pada residual kuadrat.

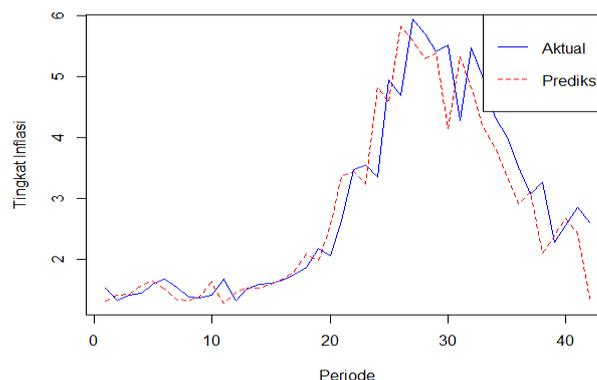
3.9. Akurasi Peramalan

Akurasi peramalan penting dilakukan untuk memberikan gambaran seberapa baik model atau metode peramalan dapat memprediksi nilai yang sebenarnya. Model yang didapatkan pada penelitian ini akan dievaluasi menggunakan ukuran ketepatan *Mean Absolute Percentage Error* (MAPE). Perhitungan nilai MAPE dilakukan pada data testing dengan jumlah data sebanyak 42 pengamatan. Hasil perhitungan MAPE disajikan pada Tabel 9.

Tabel 9. Hasil Perhitungan Nilai MAPE

Model	Nilai MAPE (%)
ARIMA(0,1,1)-GARCH(1,1)	12,42

Tabel 9 menunjukkan hasil perhitungan nilai MAPE pada model GARCH(1,1) yang diperoleh sebesar 12,42%. Artinya prediksi model cenderung memiliki kesalahan sekitar 12,42% dari nilai aktual secara rata-rata. Model yang didapatkan memiliki kemampuan peramalan yang baik karena nilai MAPE kurang dari 20%. Adapun grafik perbandingan antara data aktual dan hasil prediksi untuk data *testing* disajikan pada Gambar 6.



Gambar 6. Perbandingan data aktual dan hasil prediksi



3.10. Penerapan Kalman Filter

Penerapan Kalman Filter merupakan suatu estimasi dengan tahapan prediksi satu langkah kedepan dan kemudian dikoreksi dengan data aktual, sehingga dapat diestimasi nilai *error* dengan menggunakan besaran nilai kovarian yaitu *noise* sistem dan *noise* pengukuran. Dengan nilai kovarian yang diasumsikan diharapkan terdapat pengaruh terhadap hasil estimasi tingkat inflasi nasional [12]. Penerapan Kalman Filter dilakukan dengan menggunakan persamaan polinomial derajat 1 dan polinomial derajat 2 yang membentuk persamaan sebagai berikut:

$$u_i^0 = a_{0,i} + a_{1,i}m_i \text{ dengan } x_t = \begin{bmatrix} a_{0,1} \\ a_{1,1} \end{bmatrix} \text{ dan } z_t = [1 \ 0]$$

$$u_2^0 = a_{0,2} + a_{1,2}m_i + a_{2,2}m_i^2 \text{ dengan } x_t = \begin{bmatrix} a_{0,2} \\ a_{1,2} \\ a_{2,2} \end{bmatrix} \text{ dan } z_t = [1 \ 0 \ 0]$$

Model sistem Filter Kalman untuk polinomial derajat 1 dan 2 adalah sebagai berikut:

$$x_{t+1} = A_t x_t + w_t$$

dapat dituliskan dalam bentuk state space sebagai berikut untuk polinomial derajat 1:

$$\begin{bmatrix} a_{0,1} \\ a_{1,1} \end{bmatrix}_{t+1} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} a_{0,1} \\ a_{1,1} \end{bmatrix}_t + w_t$$

untuk polinomial derajat 2:

$$\begin{bmatrix} a_{0,2} \\ a_{1,2} \\ a_{2,2} \end{bmatrix}_{t+1} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} a_{0,2} \\ a_{1,2} \\ a_{2,2} \end{bmatrix}_t + w_t$$

dan model pengukuran

$$z_t = H_t x_t + v_t$$

dengan u_i^0 sebagai variabel pengukuran maka diperoleh model pengukuran z_t dalam bentuk *state space* sebagai berikut untuk polinomial derajat 1:

$$z_t = [1 \ 0] \begin{bmatrix} a_{0,1} \\ a_{1,1} \end{bmatrix}_t + v_t$$

untuk polinomial derajat 2:

$$z_t = [1 \ 0 \ 0] \begin{bmatrix} a_{0,2} \\ a_{1,2} \\ a_{2,2} \end{bmatrix}_t + v_t$$

Nilai awal variansi dan *noise* diasumsikan $Q = 0,01$ dan $R = 0,01$. Dengan polinomial derajat 1:

$$P_0 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \text{ dan } Q_t = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} Q$$

untuk polinomial derajat 2:

$$P_0 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \text{ dan } Q_t = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} Q$$

Untuk nilai awal $a_{0,i}$ dan $a_{1,i}$ diperoleh dari nilai hasil peramalan tingkat inflasi Indonesia pada model GARCH(1,1) pada data *testing* untuk bulan pertama dan bulan kedua untuk polinomial derajat 1

$$\hat{x}_0 = \begin{bmatrix} 1,3154 \\ 1,4109 \end{bmatrix} \text{ dan bulan pertama, bulan kedua dan bulan ketiga untuk polinomial derajat 2}$$

$$\hat{x}_0 = \begin{bmatrix} 1,3154 \\ 1,4109 \\ 1,4263 \end{bmatrix}.$$

Kemudian dilanjutkan pada tahap prediksi dan tahap koreksi. Tahap prediksi dilakukan dengan menggunakan persamaan berikut:

$$\hat{x}_{\bar{t}+1} = A_t \hat{x}_t$$

$$P_{\bar{t}+1} = A_t P_t A_t^T + Q_t$$

Sedangkan tahap koreksi dilakukan sebagai berikut, Kalman Gain didapatkan dengan menggunakan nilai kovarian error pada tahap prediksi.

$$K_{t+1} = P_{\bar{t}+1} H_{t+1}^T (H_{t+1} P_{\bar{t}+1} H_{t+1}^T + R_{t+1})^{-1}$$

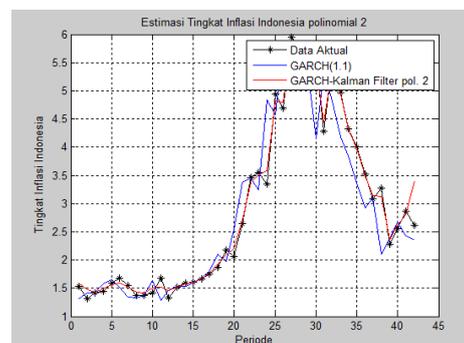
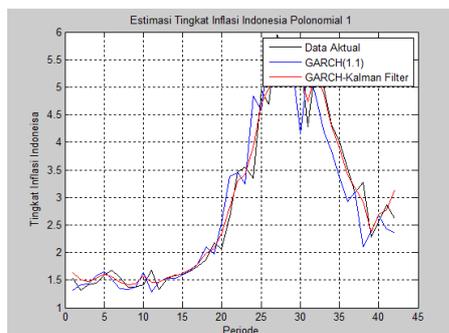
Setelah mendapatkan nilai matriks kalman gain, lalu nilai \hat{x}_{t+1} diestimasi dengan menggunakan nilai $\hat{x}_{\bar{t}+1}$ yang diperoleh dari tahap prediksi.

$$\hat{x}_{t+1} = \hat{x}_{\bar{t}+1} + K_{t+1} [z_{t+1} - H_{t+1} \hat{x}_{\bar{t}+1}]$$

Kemudian, nilai P_{t+1} didapatkan dengan menggunakan nilai $P_{\bar{t}+1}$ yang telah diperoleh pada tahap prediksi dan nilai Kalman Gain pada tahap koreksi.

$$P_{t+1} = [1 - K_{t+1} H_{t+1}] P_{\bar{t}+1}$$

Untuk proses simulasi Kalman Filter telah dilakukan dengan menggunakan bantuan *software* Matlab. Hasil estimasi data tingkat inflasi Indonesia menggunakan Kalman Filter derajat polinomial 1 dan polinomial derajat 2 didapat dilihat pada Gambar 7.



Gambar 7a. Plot akurasi Kalman Filter Polinomial derajat 1 **Gambar 7b.** Plot akurasi Kalman Filter Polinomial derajat 2
Gambar 7. Peramalan Inflasi di Indonesia dengan ARIMA(0,1,1)-GARCH(1,1) berbasis optimasi Kalman Filter Polinomial derajat 1 dan 2



Pada gambar 7 dapat dilihat bahwa peramalan tingkat inflasi Indonesia menggunakan Kalman Filter polinomial derajat 1 dan 2 lebih mendekati data aktual dibandingkan dengan menggunakan GARCH(1,1). Dari simulasi perbaikan *error* menggunakan Kalman Filter didapatkan hasil simulasi dengan persamaan polinomial derajat 1 untuk sebagai berikut:

$$u_i^0 = -1,7499 + 0,7352m_i$$

untuk polinomial derajat 2:

$$u_i^0 = -1,5915 + 0,69123m_i - 0,01299m_i^2$$

Berdasarkan penerapan metode Kalman Filter Polinomial derajat 1 dan 2 pada model ARIMA(0,1,1)-GARCH(1,1), dihasilkan kesalahan prediksi berdasarkan nilai MAPE yang disajikan pada Tabel 11.

Tabel 11. Perbandingan Nilai MAPE

Model	Nilai MAPE (%)
GARCH(1,1)	12,42
GARCH-Kalman Filter Polinomial Derajat 1	5,71
GARCH-Kalman Filter Polinomial Derajat 2	3,60

Nilai MAPE data tingkat inflasi Indonesia dengan menggunakan perbaikan *error* Kalman Filter polinomial derajat 1 diperoleh nilai MAPE sebesar 5,71% sedangkan polinomial derajat 2 menghasilkan nilai MAPE sebesar 3,60%. Hasil tersebut menunjukkan bahwa penerapan optimasi Kalman Filter mampu meningkatkan akurasi hasil peramalan jika dibandingkan tanpa menggunakan optimasi Kalman Filter.

3.11. Hasil Peramalan

Setelah didapatkan model ARIMA(0,1,1)-GARCH(1,1) dengan optimasi Kalman Filter Polinomial 2 sebagai model terbaik, selanjutnya dilakukan prediksi selama 6 periode kedepan. Berdasarkan hasil peramalan, rata-rata tingkat inflasi Indonesia pada tahun 2024 periode Januari sampai dengan Juli diperkirakan berada dalam rentang 2% hingga 3%. Hasil peramalan untuk tingkat inflasi Indonesia dapat dilihat pada Tabel 11.

Tabel 11. Hasil Peramalan Tingkat Inflasi

Tahun	Bulan	Data Ramalan (%)
2024	Januari	2,06
	Februari	2,43
	Maret	2,59
	April	2,60
	Mei	2,61
	Juli	2,61

IV. KESIMPULAN

Inflasi negara Indonesia dari tahun 2010 berfluktuasi cukup tinggi hingga menembus 8,79% di bulan Agustus 2013 dan kemudian mulai stabil disekitaran 1% hingga 4% dari tahun 2016. Peramalan inflasi di Indonesia penting dilakukan untuk mendukung pihak yang berkepentingan dalam pengambilan kebijakan untuk menjaga stabilitas ekonomi negara, menjaga daya beli masyarakat, dan mendukung pertumbuhan ekonomi yang berkelanjutan. Model terbaik untuk meramalkan Inflasi di Indonesia adalah ARIMA(0,1,1)-GARCH(1,1) dengan optimasi Kalman Filter Polinomial 2 sebagai model terbaik karena memiliki nilai kesalahan prediksi MAPE terkecil 3,60%.



REFERENSI

1. Yesika, “Prosedur investasi emas berjangka,” Sekolah Tinggi Ilmu Ekonomi Kesatuan, 2014.
2. Bank Indonesia, “Data Inflasi,” 2023. [Online]. Available: <https://www.bi.go.id/id/statistik/indikator/data-inflasi.aspx>.
3. V. Sutriani, “Peramalan Tingkat Inflasi di Indonesia Tahun 2022 Menggunakan Metode Holt-Winters dengan Optimasi Golden Section,” in *Seminar Nasional Matematika, Geometri, Statistika, dan Komputasi SeNa-MaGeStiK 2022*, 2022, pp. 392–404.
4. BPS, “Indeks Harga Konsumen dan Inflasi Bulanan Indonesia, 2006-2023,” 2024. [Online]. Available: <https://www.bps.go.id/id/statistics-table/1/OTA3IzE=/indeks-harga-konsumen-dan-inflasi-bulanan-indonesia-2006-2023.html>.
5. R. F. Sianti, S. D. Surjanto, and E. Apriliani, “Estimasi Tingkat Inflasi Nasional Menggunakan ARCH-GARCH Filter Kalman,” *J. Sains dan Seni ITS*, vol. 11, no. 2, 2022, doi: 10.12962/j23373520.v11i2.75827.
6. R. P. N. Utami, M. Al Haris, and R. Wasono, “Analisis risiko pada Saham PT . Unilever Indonesia dengan metode expected shortfall berdasarkan model GBM with jump diffusion,” *MIMS Maj. Ilm. Mat. dan Stat.*, vol. 23, no. 2, pp. 116–127, 2023, doi: <https://doi.org/10.19184/mims.v23i2.38459>.
7. I. F. Amri, W. Sari, V. A. Widayarsi, N. Nurohmah, and M. Al Haris, “The ARIMA-GARCH Method in Case Study Forecasting the Daily Stock Price Index of PT. Jasa Marga (Persero),” *Eig. Math. J.*, vol. 7, no. 1, pp. 25–33, 2024, doi: 10.29303/emj.v7i1.174.
8. N. Untari, A. A. Mattjik, and A. Saefuddin, “Analisis Deret Waktu dengan Ragam Galat Heterogen dan Asimetrik Studi Indeks Harga Saham Gabungan (IHSG) Periode 1999-2008,” *Forum Stat. dan Komputasi*, vol. 14, no. 1, pp. 22–33, 2009.
9. R. F. Engle, “Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation,” *Econom. Soc.*, vol. 50, no. 4, pp. 987–1007, 1982.
10. L. N. Rahmawati, M. Mardijah, and A. Hakam, “Penerapan Metode Kalman Filter dalam Estimasi Harga Saham Menggunakan Model ARCH-GARCH,” *J. Sains dan Seni ITS*, vol. 12, no. 1, 2023, doi: 10.12962/j23373520.v12i1.96240.
11. R. E. Kalman, “A new approach to linear filtering and prediction problems,” *J. Fluids Eng. Trans. ASME*, vol. 82, no. 1, pp. 35–45, 1960, doi: 10.1115/1.3662552.
12. R. Sholehurrohman, M. R. Habibi, I. S. Ilman, R. Taufiq, and Muhaqiqin, “Analisis Metode Kalman Filter, Particle Filter dan Correlation Filter untuk Pelacakan Objek,” *Komputika J. Sist. Komput.*, vol. 12, no. 2, pp. 21–28, 2023, doi: 10.34010/komputika.v12i2.9567.
13. M. Al Haris and P. R. Arum, “Peramalan Harga Emas dengan Model Generalized Autoregressive Conditional Heteroscedasticity (GARCH),” *J. Sainika Unpam J. Sains dan Mat. Unpam*, vol. 3, no. 1, 2020, doi: 10.32493/jsmu.v3i1.5263.
14. S. H. Prabuningrat, M. Al Haris, N. K. Salma, P. W. Muharamah, and M. S. Nur, “Peramalan Indeks Harga Konsumen Kota Semarang dengan Metode Autoregressive Integrated Moving Average,” *J. Data Insights*, vol. 1, no. 1, pp. 1–9, 2023, doi: 10.26714/jodi.v1i1.124.
15. S. Ghosh, K. N. Singh, A. Thangasamy, D. Datta, and A. Lama, “Forecasting of onion (*Allium cepa*) price and volatility movements using ARIMAX-GARCH and DCC models,” *Indian J. Agric. Sci.*, vol. 90, no. 5, pp. 1009–1013, Sep. 2020, doi: 10.56093/ijas.v90i5.104384.
16. A. P. Desvina and I. O. Meijer, “Penerapan Model ARCH/GARCH untuk Peramalan Nilai Tukar Petani,” *J. Sains Mat. dan Stat.*, vol. 4, no. 1, pp. 43–54, 2018, doi: <http://dx.doi.org/10.24014/jsms.v4i1.5256>.