

# Model *Autoregressive Moving Average* (ARMA) untuk Peramalan Tingkat Inflasi di Indonesia

Khoirunnisa Rohadatul Aisy Muslihin<sup>1</sup>, Budi Nurani Ruchjana<sup>2\*</sup>

<sup>1,2</sup> Departemen Matematika, FMIPA, Universitas Padjadjaran

e-mail:budi.nurani@unpad.ac.id

*Diajukan: 26 Januari 2023, Diperbaiki: 15 Februari 2023, Diterima: 15 Februari 2023*

## Abstrak

Salah satu faktor yang mempengaruhi pertumbuhan perekonomian suatu negara adalah besarnya tingkat inflasi. Pentingnya menjaga kestabilan tingkat inflasi dikarenakan adanya pengaruh negatif terhadap kondisi sosial dan ekonomi negara yang diakibatkan oleh tingkat inflasi yang tinggi dan tidak stabil. Oleh karena itu peramalan dapat dilakukan sebagai salah satu upaya menjaga kestabilan tingkat inflasi. Penelitian ini membahas mengenai penggunaan model deret waktu *Autoregressive Moving Average* (ARMA) dalam meramalkan tingkat inflasi di Indonesia. Data tingkat inflasi dianalisis untuk menentukan model yang terbaik untuk peramalan. Dengan menggunakan data bulanan tingkat inflasi di Indonesia dari Januari 2016 sampai Desember 2021, diperoleh model terbaik yaitu model ARMA(3,3) berdasarkan nilai *Akaike Information Criterion* terkecil. Hasil analisis menunjukkan bahwa tingkat inflasi pada bulan Januari 2022 hingga Maret 2022 berada di sekitar 0,2%. Pola grafik hasil prediksi mengikuti pola data aktual sehingga model ARMA(3,3) baik untuk digunakan.

**Kata Kunci:** inflasi, peramalan, deret waktu, ARMA.

## Abstract

*One of the factors that influence a country's economic growth is the high rate of inflation. The importance of maintaining a stable inflation rate is due to the negative impact on the country's social and economic conditions caused by high and unstable inflation rates. Therefore, forecasting can be done as an effort to maintain a stable inflation rate. This study discusses the use of the Autoregressive Moving Average (ARMA) time series model in forecasting the inflation rate in Indonesia. Inflation rate data is analyzed to determine the best model for forecasting. By using monthly data on the inflation rate in Indonesia from January 2016 to December 2021, the best model is obtained, namely the ARMA(3.3) model based on the smallest Akaike Information Criterion value. The results of the analysis show that the inflation rate in January 2022 to March 2022 is around 0.2%. The predicted graph pattern follows the actual data pattern so that the ARMA(3,3) model is good to use.*

**Keywords:** *inflation, forecasting, time series, ARMA.*

## 1 Pendahuluan

Inflasi di Indonesia merupakan permasalahan ekonomi yang cukup penting. Inflasi adalah keadaan dimana harga barang dan jasa naik secara umum dalam suatu negara [1]. Inflasi dapat dipengaruhi oleh beberapa faktor, diantaranya pengeluaran pemerintah, jumlah uang yang beredar, dan suku bunga [2]. Di Indonesia, tingkat inflasi memberikan pengaruh terhadap pertumbuhan ekonomi negara. Berdasarkan Septiatin, Mawardi, dan Rizki [3], inflasi dapat menyebabkan

perubahan yang positif dalam perekonomian, terutama jika tingkat inflasi rendah dan tidak melebihi 10%, karena dapat mendorong para pengusaha untuk meningkatkan produktivitas. Walaupun demikian, tingkat inflasi yang tinggi dan tidak stabil dapat menyebabkan efek negatif pada perekonomian suatu negara, seperti menurunkan daya beli masyarakat dan menurunkan tingkat investasi. Lubis [4] menyatakan bahwa inflasi dan pertumbuhan ekonomi di Indonesia berkorelasi negatif, artinya pertumbuhan ekonomi akan mengalami penurunan ketika inflasi meningkat. Karenanya, dibutuhkan tindakan untuk mengendalikan inflasi pada tingkat yang rendah dan stabil.

Peramalan terhadap tingkat inflasi dapat dilakukan sebagai sarana membantu pemerintah dalam mengambil kebijakan. Perhitungan tingkat inflasi yang bergantung dari waktu ke waktu dapat dilakukan dengan menggunakan analisis deret waktu (*time series*). Analisis deret waktu digunakan untuk menganalisis data yang bersifat temporal, yaitu data yang diambil pada waktu tertentu [5]. Metode ini dapat digunakan untuk memahami pola, trend, dan variasi yang terjadi dalam data yang diambil dari waktu ke waktu. Beberapa penelitian yang dilakukan dengan menggunakan deret waktu diantaranya adalah Sulaiman [5] yang membahas mengenai peramalan tingkat pengangguran di Indonesia. Selain itu analisis deret waktu digunakan juga untuk memodelkan indeks harga saham oleh Susanti dan Adji [7] serta Hansun [6].

Salah satu model yang digunakan untuk menganalisis data deret waktu diantaranya adalah *Autoregressive Moving Average* (ARMA). Model ARMA terdiri dari dua komponen utama, yaitu *Autoregression* (AR) dan *Moving Average* (MA). *Autoregression* (AR) adalah suatu proses dimana variabel yang diamati diprediksi berdasarkan nilai-nilai sebelumnya. Sedangkan *Moving Average* (MA) adalah suatu proses dimana variabel yang diamati diprediksi berdasarkan rata-rata nilai-nilai acak dari waktu sebelumnya. Model ini banyak dipakai dalam berbagai bidang antara lain ekonomi [8, 9], cuaca [10], dan kesehatan [11, 12].

Pada penelitian ini, tingkat inflasi di Indonesia dimodelkan dengan menggunakan model ARMA. Kemudian, model yang diperoleh digunakan untuk memprediksi tingkat inflasi pada periode selanjutnya.

## 2 Metode Penelitian

### 2.1 Deret Waktu (*Time Series*)

Data deret waktu (*time series*) adalah sekumpulan data yang diambil pada waktu tertentu, biasanya dengan interval waktu yang sama [13]. Data deret waktu memiliki beberapa karakteristik

unik yang membedakannya dengan data lainnya yang meliputi temporalitas, yaitu data diambil pada waktu tertentu, stasioneritas, dan autokorelasi.

## 2.2 Stasioneritas

Data stasioner merupakan data memiliki nilai rata-rata dan variansi yang stabil, sementara data yang tidak stasioner memiliki nilai rata-rata dan variansi yang berubah seiring dengan berubahnya waktu [14]. Pada penelitian ini, stasioneritas data terhadap rata-rata diidentifikasi menggunakan uji akar unit *Augmented Dickey Fuller* (ADF). Rumusan hipotesis yang digunakan adalah sebagai berikut.

$$H_0 : \gamma = 0 \text{ (tidak stasioner)}$$

$$H_1 : \gamma \neq 0 \text{ (stasioner)}.$$

Untuk melihat kestasioneran data digunakan rumus

$$\tau = \left| \frac{\hat{\gamma}}{SE(\hat{\gamma})} \right|,$$

dengan  $\tau$  adalah nilai  $t$  hitung,  $\hat{\gamma}$  merupakan nilai taksiran parameter,  $SE(\hat{\gamma})$  adalah standar *error* dari  $\hat{\gamma}$ . Jika  $\tau > t$  tabel atau  $p\text{-value} < 0,05$  maka diambil keputusan tolak  $H_0$ .

## 2.3 *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF)

Dalam analisis deret waktu, *Autocorrelation Function* (ACF) digunakan untuk melihat tingkat korelasi dari hubungan linier dua variabel, misalnya hubungan linier antar dua nilai lag pada deret waktu [15].

Kovarians antara  $Z_t$  dan  $Z_{t+k}$  diberikan oleh

$$\gamma_k = \text{Cov}(Z_t, Z_{t+k}) = E(Z_t - \bar{Z})(Z_{t+k} - \bar{Z}) = \sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}), \quad (1)$$

dan korelasi antara  $Z_t$  dengan  $Z_{t+k}$  adalah

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \mu)(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, \quad (2)$$

dengan  $\gamma_k$  adalah kovarians pada lag  $k$ ,  $\rho_k$  menyatakan autokorelasi pada lag  $k$ ,  $Z_t$  adalah data pada periode  $t$ , dan  $\bar{Z}$  menyatakan rata-rata data.

Sedangkan *Partial Autocorrelation Function* (PACF) digunakan untuk menunjukkan ukuran korelasi antara observasi pada waktu yang berbeda dengan observasi pada waktu yang sama setelah korelasi antara observasi saat ini tanpa memperhitungkan korelasi yang terdapat pada lag 1, 2, 3, ...,  $t - k + 1$  [16]. PACF dapat diperoleh dengan rumus berikut.

$$\hat{\phi}_{kk} = \frac{\hat{\rho}_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \rho_j}, \quad (3)$$

dengan  $\hat{\phi}_{ii}$  menyatakan autokorelasi parsial lag  $i$ ,  $\hat{\rho}_i$  menyatakan autokorelasi lag  $i$ ,  $\hat{\phi}_{k-1,j}$  menyatakan autokorelasi parsial lag  $k-1, j$ ,  $\rho_{k-j}$  merupakan autokorelasi lag  $k-j, j$ , dan  $\rho_j$  menyatakan autokorelasi lag  $j$ ,  $j = 1, 2, 3, \dots, k-1$ .

#### 2.4 Model Autoregressive Moving Average (ARMA)

Model Autoregressive Moving Average (ARMA) berasal dari gabungan model deret waktu Autoregressive (AR) dan Moving Average (MA). Model AR digunakan dalam analisis deret waktu untuk menentukan hubungan antara observasi saat ini dengan observasi sebelumnya. Berdasarkan Wei [16], model AR dengan orde  $p$ , disebut dengan AR( $p$ ), diberikan oleh

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t, \quad (4)$$

dengan  $Z_t$  merupakan deret waktu,  $\phi_p$  adalah parameter AR ke- $p$ ,  $a_t$  adalah *error* pada waktu ke- $t$ , dan  $\mu$  adalah konstanta. Dengan menggunakan operator *backshift*  $B$ , dengan  $B^j x_t = x_{t-j}$ , model AR ( $p$ ) dapat dituliskan sebagai

$$\phi(B)\dot{Z}_t = a_t, \quad (5)$$

dengan  $\dot{Z}_t = Z_t - \mu$  dan  $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$  adalah polinomial di  $B$  dengan orde  $p$ .

Model MA menggambarkan keterkaitan antara nilai observasi dari kesalahan peramalan saat ini dan nilai *error* peramalan masa lalu yang berurutan [16]. Model MA dengan orde  $q$ , dinotasikan oleh MA( $q$ ), memiliki bentuk:

$$Z_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}, \quad (6)$$

dengan  $Z_t$  merupakan deret waktu,  $\theta_q$  adalah parameter *moving average* ke- $q$ , dan  $a_t$  adalah nilai *error* pada waktu  $t$ . Model MA( $q$ ) juga dapat dinyatakan dalam bentuk

$$\dot{Z}_t = \theta(B)a_t, \quad (7)$$

dengan  $\dot{Z}_t = Z_t - \mu$ ,  $B$  merupakan operator *backshift*, dan  $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ .

Dalam model ARMA diasumsikan bahwa data periode saat ini dipengaruhi oleh data dan tingkat *error* periode sebelumnya. ARMA( $p, q$ ) menotasikan model ARMA dengan orde  $p$  dan  $q$ . Bentuk umum dari model ini diberikan sebagai berikut [16]:

$$Z_t = \delta + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}, \quad (8)$$

dengan  $Z_t$  menyatakan variabel deret waktu,  $\delta$  konstanta,  $\theta_q$  koefisien parameter MA pada saat ke- $q$ ,  $\phi_p$  koefisien parameter AR pada saat  $p$ , dan  $a_{t-q}$  *error* pada saat ke  $t - q$ . Model ARMA( $p, q$ ) juga dapat dituliskan sebagai

$$\phi(B)\dot{Z}_t = \theta(B)a_t. \quad (9)$$

#### 2.5 Akaike Information Criterion (AIC)

Akaike Information Criterion (AIC) digunakan untuk menguji ketepatan suatu model. AIC secara asimtotik memilih model yang meminimalkan kuadrat *error* dari prediksi atau estimasi. AIC

juga meminimalkan kemungkinan risiko maksimum dalam ukuran sampel yang terbatas [17]. Nilai AIC dapat dihitung sebagai berikut.

$$AIC = n \ln \left( \frac{SSE}{n} \right) + 2f + n + n \ln(2\pi), \quad (10)$$

dengan SSE menyatakan jumlah eror kuadrat (*sum square error*),  $f$  menyatakan banyaknya parameter dalam model, dan  $n$  menyatakan banyaknya data. Model ARMA terbaik ditentukan dengan memilih nilai AIC yang terkecil.

## 2.6 Uji Diagnostik Model

Uji diagnostik model merupakan proses yang dilakukan untuk memeriksa kualitas model yang digunakan dalam peramalan. Penelitian ini menggunakan uji Ljung-Box dengan hipotesis yang diberikan sebagai berikut [16]:

$$H_0 : \hat{\rho}_k = 0 \text{ (residual merupakan } white \text{ noise)}$$

$$H_1 : \hat{\rho}_k \neq 0 \text{ (residual bukan } white \text{ noise).}$$

dengan statistik uji

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-K},$$

dengan  $\hat{\rho}_k$  merupakan koefisien autokorelasi residual pada lag  $k$ ,  $K$  menyatakan lag maksimum, dan  $n$  adalah jumlah data. Jika  $Q > \chi_{\alpha; df=k-p-q}^2$  atau  $p$ -value lebih dari  $\alpha$  maka diambil keputusan tolak  $H_0$  yang berarti bahwa autokorelasi residual tidak signifikan dan model layak digunakan.

## 2.7 Root Mean Square Error (RMSE)

RMSE merupakan perhitungan eror yang dihitung dengan rumus [18]:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{x}_i - x_i)^2}{n}},$$

dengan  $x_i$  merupakan nilai objek pengamatan ke- $i$ ,  $\hat{x}_i$  merupakan hasil peramalan ke- $i$ , dan  $n$  banyaknya data.

## 2.8 Sumber Data

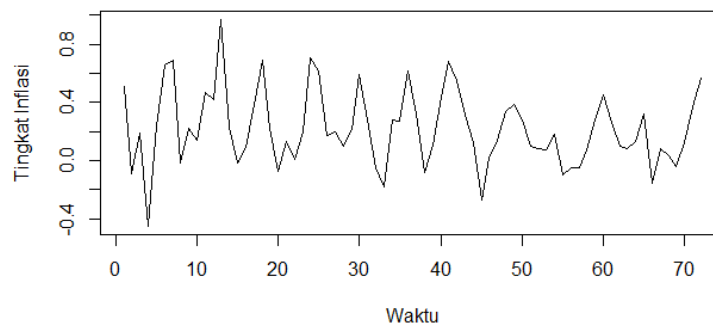
Data yang digunakan dalam penelitian ini merupakan data tingkat inflasi di Indonesia dari Januari 2016 hingga Desember 2021 yang diperoleh dari situs web Bank Indonesia. Analisis data dalam penelitian dilakukan dengan bantuan *software* Rstudio. Adapun langkah-langkah yang dilakukan adalah sebagai berikut.

1. Mengidentifikasi kestasioneran data
  - a. Melakukan plot data,
  - b. Menguji kestasioneran data menggunakan uji ADF

- c. Apabila data tidak stationer maka dilakukan *differencing* untuk menstasionerkan data.
2. Mengidentifikasi model order model ARMA melalui *plot* ACF dan PACF
3. Melakukan estimasi parameter model
4. Model terbaik dipilih dengan memperhatikan kriteria AIC dengan didasarkan nilai AIC terkecil.
5. Melakukan uji diagnostik model.
6. Melakukan peramalan.

### 3 Hasil dan Pembahasan

Plot data tingkat inflasi di Indonesia dari bulan Januari 2016 sampai Desember 2021 ditunjukkan pada Gambar 1.




**Gambar 1.** Plot deret waktu data tingkat inflasi di Indonesia

Pada Gambar 1, dapat dilihat bahwa plot data inflasi di Indonesia dari tahun 2016 sampai 2021 menunjukkan pola pergerakan yang stasioner. Untuk memperkuat hal ini dilakukan uji kestasioneran terhadap rata-rata menggunakan uji ADF. Hasil uji ADF dijasikan pada Tabel 1.

Tabel 1. Hasil uji ADF

Statistik Uji	<i>p-value</i>
-5,1496	0,01

Berdasarkan Tabel 1, diperoleh nilai *p-value* sebesar 0,01. Oleh karena itu dengan taraf signifikan sebesar 0,05 data tingkat inflasi telah stasioner. Selanjutnya dibuat plot ACF dan PACF dari data yang digunakan untuk memperoleh order dari model AR dan MA.



**Gambar 2.** Plot ACF dan PACF data tingkat inflasi di Indonesia

Selanjutnya akan diduga model  $ARMA(p, q)$  dengan orde  $p$  dan  $q$  ditentukan dengan memilih lag yang signifikan pada autokorelasi untuk orde  $p$  dan autokorelasi parsial untuk orde  $q$ . Berdasarkan Gambar 2, plot ACF menunjukkan bahwa autokorelasi signifikan pada lag 0, lag 1, lagi 3, lag 6, dan lag 9 sehingga orde  $q$  yang dapat dipilih adalah 0, 1, 3, 6, dan 9. Sementara itu, plot PACF menunjukkan bahwa autokorelasi parsial signifikan pada lag 1, lag 2, dan lag 3 sehingga order  $p$  yang dapat dipilih yaitu 1, 2, dan 3.

Selanjutnya dihitung nilai AIC untuk masing-masing model yang mungkin (Lihat Tabel 2). yang terkecil.

Tabel 2. Nilai AIC model ARMA yang mungkin

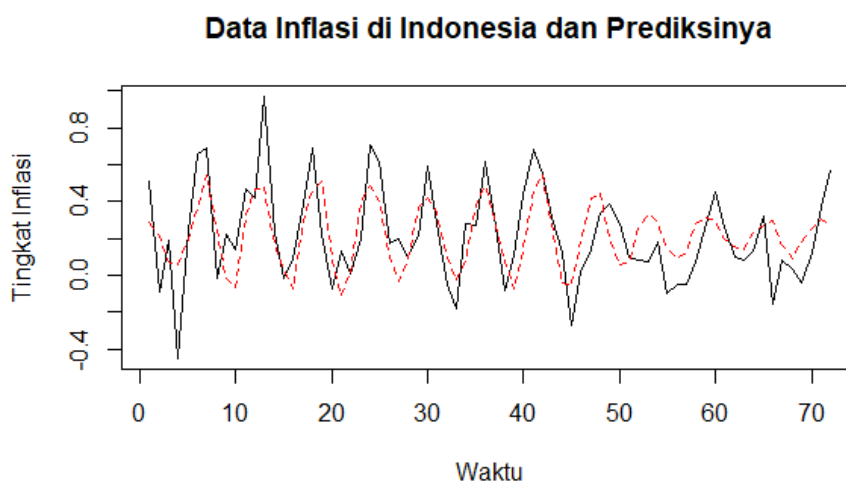
ARMA( $p, q$ )	AIC	ARMA( $p, q$ )	AIC	ARMA( $p, q$ )	AIC
ARMA(1,0)	8,82	ARMA(2,0)	4,84	ARMA(3,0)	-1,5
ARMA(1,1)	8,97	ARMA(2,1)	4,03	ARMA(3,1)	-0,89
ARMA(1,3)	6,32	ARMA(2,3)	6,15	ARMA(3,3)	-10,94
ARMA(1,6)	4,15	ARMA(2,6)	5,78	ARMA(3,6)	-10,41
ARMA(1,9)	0,21	ARMA(2,9)	1,92	ARMA(3,9)	-9,2

Berdasarkan Tabel 2 dipilih model ARMA(3,3) karena memiliki AIC yang terkecil. Persamaan model ARMA(3,3) yang diperoleh sesuai dengan (8) diberikan oleh

$$Z_t = 0,2201 + 0,0045Z_{t-1} - 0,0823Z_{t-2} - 0,9254Z_{t-3} - 0,1298a_{t-1} - 0,2099a_{t-2} - 0,8155a_{t-3} \quad (11)$$

Berdasarkan uji Ljung-Box diperoleh  $p$ -value untuk model ARMA(3,3) sebesar  $0,405 > 0,05$  oleh karena itu dapat disimpulkan bahwa residu dari model ARMA(3,3) mengikuti *white noise* dan model layak digunakan.

Langkah selanjutnya adalah melakukan prediksi menggunakan model yang telah diperoleh. Prediksi diperoleh dengan menggunakan model ARMA(3,3) pada (11). Dengan menggunakan R, diperoleh plot data prediksi tingkat inflasi pada Gambar 3.



**Gambar 3.** Data inflasi di Indonesia dan prediksinya

Pada Gambar 3, garis putus-putus berwarna merah merupakan hasil prediksi tingkat inflasi di Indonesia yang diperoleh menggunakan model ARMA(3,3). Gambar 3 menggambarkan bahwa hasil prediksi inflasi di Indonesia mengikuti pola yang sama dengan data aktual, yang menunjukkan bahwa model ini cocok digunakan dan sesuai dengan data yang sebenarnya. Adapun dengan menggunakan model ARMA(3,3) pada persamaan (11) diperoleh prediksi tingkat inflasi di Indonesia pada bulan Januari 2022 sebesar 0,206%, Februari sebesar 0,208%, dan Maret sebesar 0,209% dengan RMSE sebesar 0,196. Selain itu nilai RMSE yang menuju nol juga menunjukkan bahwa hasil peramalan mendekati nilai yang aktual.

#### 4 Simpulan

Dalam penelitian ini, model ARMA digunakan untuk mengidentifikasi pola pada data inflasi di Indonesia. Hasil analisis menunjukkan bahwa model ARMA(3,3) adalah model terbaik karena memiliki nilai AIC yang paling kecil. Berdasarkan hasil prediksi yang dilakukan menggunakan model ARMA(3,3) diperkirakan bahwa tingkat inflasi di Indonesia akan menurun pada bulan Januari 2022 sebesar 0,206%, naik pada bulan Februari 2022 sebesar 0,208% dan naik lagi pada bulan Maret 2022 sebesar 0,209%, dengan nilai RMSE sebesar 0,196.

#### 5 Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Rektor Universitas Padjadjaran atas dukungan dana untuk diseminasi hasil riset dosen dan mahasiswa melalui Academic Leadership Grant dengan nomor kontrak: 2203/UN6.3.1/PT.00/2022 serta Pusat Studi Pemodelan dan Komputasi FMIPA Universitas Padjadjaran.



## 6 Daftar Pustaka

- [1] N. M. Baily and P. Friedman, *Macroeconomics, Financial Markets, and the International Sector*, 2nd ed. New York: Irwin, 1995.
- [2] E. Silvia, Y. Wardi, and H. Aimon, “Analisis Pertumbuhan Ekonomi, Investasi, Dan Inflasi Di Indonesia,” *J. Kaji. Ekon.*, vol. 1, no. 2, p. 7105, 2013.
- [3] A. Septiatin, Mawardi, M. A. K. Rizki, K. Rizki, and E. D. I. Indonesia, “Pengaruh Inflasi Dan Tingkat Pengangguran Terhadap Pertumbuhan Ekonomi Di Indonesia,” *I-Economics A Res. J. Islam. Econ.*, vol. 2, no. 1, pp. 50–65, 2016.
- [4] I. F. Lubis, “Analisis Hubungan Antara Inflasi dan Pertumbuhan Ekonomi: Kasus Indonesia,” *Quant. Econ. J.*, vol. 3, no. 1, 2014.
- [5] A. Sulaiman and A. Juarna, “Peramalan Tingkat Pengangguran Di Indonesia Menggunakan Metode Time Series Dengan Model Arima Dan Holt-Winters,” *J. Ilm. Inform. Komput.*, vol. 26, no. 1, pp. 13–28, 2021.
- [6] S. Hansun, “Peramalan data IHSG menggunakan fuzzy time series,” *IJCCS (Indonesian J. Comput. Cybern. Syst.)*, vol. 6, no. 2, 2012.
- [7] R. Susanti and A. R. Adji, “Analisis Peramalan Ihsg Dengan Time Series Modeling Arima,” *J. Manaj. Kewirausahaan*, vol. 17, no. 1, pp. 97–106, 2020.
- [8] M. Kun and L. Li, “Empirical Analysis of Stock Price Based on ARMA Model,” *J. Hebei North Univ. (Natural Sci. Ed.)*, p. 05, 2016.
- [9] T. Li and F. Chen, “An Empirical Analysis of Hunan’s Consumer Price Index Based on ARMA Model,” *Sch. J. Econ. Bus. Mangement*, 2018.
- [10] H. Rezaie and M. Khoshbakht Tizkharab, “Rainfall Forecast by Integrated Model ARMA-ARCH for West of Urmia Lake Catchment basin,” *J. Civ. Environ. Eng.*, vol. 49.2, no. 95, pp. 85–94, 2019.
- [11] M. V Lyakhnova and G. S. Ruadev, “COVID-19 SIMULATION USING ARMA MODELS,” *Mod. Sci.*, no. 2–1, pp. 37–43, 2021.
- [12] Y. Lyu, “Time Series Analysis of the COVID-19 Impact on the US Airline Companies Based on ARMA model,” *Proc. 2021 Int. Conf. Control Intelegent Robot.*, 2021.
- [13] D. Rosadi, *Pengantar Analisa Runtun Waktu*. Yogyakarta: FMIPA UGM, 2006.
- [14] A. Widarjono, *Ekonometrika: Teori dan Aplikasi untuk Ekonomi dan Bisnis*. Yogyakarta: Ekonisia, 2005.
- [15] S. Makridakis, S. C. Wheelwright, and V. E. McGee, *Metode dan Aplikasi Peramalan*.

Jakarta: Erlangga, 1999.

- [16] W. W. S. Wei, *Time Series Analysis*, 2nd ed. Addison Wesley Publishing Company, 2006.
- [17] S. I. Vrieze, "Model selection and psychological theory: a discussion of the differences between the Akaike information criterion (AIC) and the Bayesian information criterion (BIC).," *Psychol. Methods*, vol. 17, no. 2, p. 228, 2012.
- [18] C. J. Willmott and K. Matsuura, "Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance," *Clim. Res.*, vol. 30, no. 1, pp. 79–82, 2005.