

Implementasi *Autoregressive Integrated Moving Average* (Arima) dalam Prediksi Jumlah Penduduk Miskin Kota Tanjungpinang

Musliha¹, Nurfalinda², Muhamad Radzi Rathomi³

^{1,3}Department of Informatics Engineering, Universitas Maritim Raja Ali Haji, Indonesia

Article Info

Article history:

Received Jan 22, 2025

Revised Nov 12, 2025

Accepted Jan 29, 2026

Keywords:

ARIMA

Prediction

Number of Poor Residents

MAPE

ABSTRACT

Poverty is one of the major development challenges facing developing countries, including Indonesia, particularly in Tanjungpinang City. The main problem addressed in this study is the lack of an accurate short-term predictive model to estimate the number of poor residents, which informs policy formulation. This research proposes using the Autoregressive Integrated Moving Average (ARIMA) model to predict the number of poor people in Tanjungpinang City. The data used are monthly time series from 2015 to 2022, comprising 96 observations. The research stages include stationarity testing, differencing, model identification, parameter estimation, significance testing, and accuracy evaluation using Mean Absolute Percentage Error (MAPE). The results show that the best model is ARIMA (1,2,0) with an MAPE of 10.6%, indicating good prediction accuracy. Based on this model, the number of poor residents in Tanjungpinang City in January 2023 is projected to be 18.302 thousand. These findings are expected to serve as a quantitative reference for local governments in designing data-driven poverty alleviation policies.

Copyright © 2025 Universitas Indraprasta PGRI.
All rights reserved.

Corresponding Author:

Nurfalinda

Department of Informatics Engineering,

Universitas Maritim Raja Ali Haji,

Jl. Politeknik – Senggarang, Tanjungpinang Provinsi Kepulauan Riau.

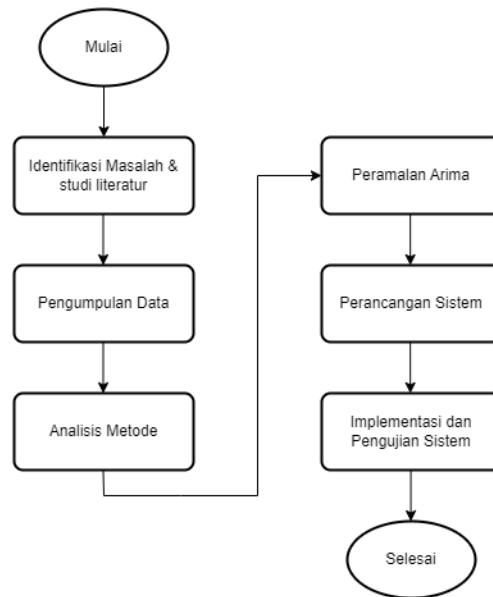
Email: nurfalinda@umrah.ac.id

1. PENDAHULUAN

Kemiskinan merupakan isu yang dihadapi hampir semua negara dan menjadi tantangan signifikan, terutama bagi negara berkembang seperti Indonesia. Di Kota Tanjungpinang, Provinsi Kepulauan Riau, kemiskinan masih menjadi permasalahan penting. Berdasarkan data Badan Pusat Statistik (BPS) Provinsi Kepulauan Riau, jumlah penduduk miskin di Kota Tanjungpinang pada tahun 2022 mencapai 27,54 ribu jiwa [1]. Kondisi ini menunjukkan bahwa kemiskinan masih memerlukan penanganan berbasis data.

Peramalan tingkat kemiskinan menjadi langkah penting dalam mendukung perencanaan dan pengambilan keputusan kebijakan[2]. Meskipun berbagai penelitian terkait kemiskinan telah dilakukan, studi yang secara khusus berfokus pada peramalan jumlah penduduk miskin di Kota Tanjungpinang dengan tingkat akurasi tinggi dan kesalahan yang rendah masih terbatas. Oleh karena itu, penelitian ini mengusulkan penggunaan metode Autoregressive Integrated Moving Average (ARIMA) untuk memprediksi jumlah penduduk miskin di Kota Tanjungpinang. Metode ARIMA dipilih karena kemampuannya dalam memodelkan data deret waktu non-stasioner dan menghasilkan prediksi dengan tingkat kesalahan yang relatif rendah. Hasil penelitian ini diharapkan dapat menyediakan model prediksi kuantitatif yang dapat dijadikan referensi oleh pemerintah Kota Tanjungpinang dalam merancang kebijakan dan alokasi sumber daya secara lebih efektif dan tepat sasaran.

2. METODE



Gambar 1. Prosedur Penelitian

2.1 Analisi Data

Data yang digunakan pada penelitian merupakan data sekunder yang diperoleh dari studi yang dilakukan oleh Muhammad Rizky (2024) dari Fakultas Teknik dan Teknologi Kemaritiman Universitas Maritim Raja Ali Haji. Dengan variabel yang digunakan berupa jumlah penduduk miskin Kota Tanjung Pinang. Data ini mencakup rentang waktu dari tahun 2015 hingga tahun 2022.

Tabel 1. Data Penduduk Miskin

No	Bulan-Tahun	Jumlah Penduduk Miskin
1	January 2015	19941
2	February 2015	19883
3	March 2015	19825
.	.	.
.	.	.
.	.	.
96	December 2022	21670

2.2 Model ARIMA

ARIMA merupakan kombinasi dari model AR (*Autoregressive*) dan model MA (*Moving Average*). Model AR digunakan dalam menjelaskan pergerakan sebuah variabel berdasarkan variabel itu sendiri pada masa sebelumnya, sedangkan model MA digunakan dalam melihat variabel melalui residual pada masa sebelumnya [3]. Proses ARIMA umumnya dilambangkan dengan (p,d,p) dimana p menunjukkan ordo atau derajat *autoregressive* (AR), d menggambarkan tingkat proses *differencing*, dan q merupakan ordo atau derajat *moving average* (MA). Adapun bentuk persamaan AR sebagai berikut :

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t \tag{1}$$

Adapun persamaan dari MA dinyatakan sebagai berikut :

$$Z_t = e_t - \theta_1 Z_{t-1} - \theta_2 Z_{t-2} - \dots - \theta_q Z_{t-q} \tag{2}$$

Rumus umum pada ARIMA sebagai berikut


$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)e_t \tag{3}$$

$$(1-B)^d (1 - \phi_1 B - \dots - \phi_p B^p) Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) e_t \tag{4}$$

2.2.1 Uji Stasioner


Tahap ini bertujuan untuk memeriksa apakah data yang digunakan telah memenuhi asumsi stasioner. Data dikatakan data stasioner apabila data tidak mengalami perubahan secara drastis atau fluktuasi yang terjadi masih berada di kisaran nilai yang konstan. Uji stasioner diperlukan sebagai syarat sebelum menentukan model menggunakan analisis time series untuk mengetahui pola data atau trend deret pengamatan. Data dikatakan stasioner jika rata-rata terpenuhi pada saat plot time series tidak mengalami atau memiliki unsur trend dan pada

grafik ACF pada data tidak ada data yang menurun secara lamban. Jika data tidak stasioner maka perlu tahapan diferensial untuk memperoleh data stasioner [2]. Dalam menguji data stasioner dapat menggunakan metode grafik atau plot time series dan uji correlogram.



Gambar 2. Plot Time Series (a) Non stasioner (b) Stasioner

Pada grafik (a) dapat dilihat terdapat pola data yang mengalami fluktuasi dan tidak menyebar di rata-rata yang menandakan data tidak stasioner [4] dan untuk grafik (b) menunjukkan pergerakan naik turun dimana angka 0 sebagai pusatnya maka data tersebut merupakan data stasioner. Pengujian data stasioner menggunakan uji correlogram dapat diamati dari pola ACF serta PACF, jika pola autokorelasi menurun dan meningkat secara perlahan menandakan data tersebut data non stasioner dan apabila data memiliki nilai autokorelasi yang mendekati nilai rata-rata nol dan grafik sudah menunjukkan tidak ada trend maka data sudah stasioner [4]. Adapun contoh *correlogram* stasioner pada gambar berikut.



Gambar 3. Correlogram (a) Stasioner (b) Non Stasioner

Pengujian correlogram dilakukan dengan menghitung nilai autokorelasi (ACF) pada persamaan (5) dan autokorelasi parsial (PACF) dengan persamaan (6).

$$\rho_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{z})(Z_{t+k} - \bar{z})}{\sum_{t=1}^n (Z_t - \bar{z})^2} \quad (5)$$

$$\phi_{kk} = \frac{\rho_1 \sum_{j=1}^{k-1} \phi_{k-j} - \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-j} \rho_{k-j}} \quad (6)$$

2.2.2 Differencing

Differencing atau proses pembedaan merupakan salah satu metode yang dilakukan bertujuan menstasionerkan data deret waktu yang dimiliki sehingga menjadi stasioner [5]. *Differencing* merupakan proses menghitung perubahan atau hasil nilai selisih dari observasi yang dilakukan. Hasil *differencing* merupakan pengurangan sebelum pengamatan (t-1) dengan data pengamatan (t). Proses ini dapat dilakukan sebanyak d kali sehingga data yang dimiliki stasioner [6]. Dalam tahapan *differencing* dilakukan dalam 3 kriteria yaitu level 0 yang mengacu pada data asli tanpa perlu differencing, level 1 yang mengacu pada data yang telah diubah dengan differencing sekali dan level 2 yang mengacu pada data yang telah diubah dengan differencing dua kali [7]. Proses differencing menggunakan persamaan berikut.

$$\nabla Z_t = Z_t - Z_{t-1} \quad (7)$$

2.2.3 Normalisasi

Normalisasi merupakan tahapan atau proses mengurangi nilai data tanpa mengubah bentuk asli data menjadi lebih kecil dengan tujuan agar data mudah untuk diproses. Dalam data set seringkali terdapat data yang tidak seragam sehingga akan mempengaruhi hasil dari analisis. Normalisasi dapat dilakukan jika data

terdapat angka 0 dengan menggunakan normalisasi interval 0,1 hingga 0,9 dengan menggunakan persamaan berikut.

$$X^* = \frac{0,8(X - \min(X))}{\max(X) - \min(X)} + 0,1 \tag{8}$$

2.2.4 Identifikasi Model

Setelah data yang digunakan melalui tahapan-tahapan sebelumnya sehingga telah memenuhi asumsi stasioner, selanjutnya mengidentifikasi model dengan membuat plot menggunakan 2 autokorelasi yaitu ACF dan PACF. Penentuan model berdasarkan grafik pada ACF dan PACF pada tabel berikut [5].

Tabel 2. Pola Plot ACF dan PACF

Proses	ACF	PACF
AR (p)	Turun secara eksponensial (<i>dies down</i>)	<i>Cuts off</i> setelah lag p
MA (q)	<i>Cuts off</i> setelah lag q	Turun secara eksponensial (<i>dies down</i>)
ARMA (p,q)	Turun secara eksponensial (<i>dies down</i>)	Turun secara eksponensial (<i>dies down</i>)

Dilihat dari tabel dalam menentukan ordo *p* yang sesuai dengan memeriksa plot nilai PACF yang memotong garis signifikansi. Sedangkan untuk ordo *q*, dapat ditentukan dengan mengamati plot nilai ACF yang memotong garis signifikansi [8]. Dalam penentuan model ARIMA dapat dilihat dari *lag* yang keluar dari garis signifikan atau garis putus-putus pada plot ACF dan plot PACF [9]. Jika dalam proses pengidentifikasian model pada grafik plot PACF dan ACF tidak ada lag yang melewati dari garis signifikansi, maka dapat disimpulkan bahwa nilai *p* dan *q* bernilai 1 [10].

2.2.4 Estimasi Parameter dan Uji Signifikansi

Estimasi parameter dilakukan setelah melakukan pengidentifikasian model ARIMA sementara dengan tujuan untuk menilai apakah parameter yang diperoleh signifikan dan dapat diterapkan sebagian konstanta model [11]. Parameter yang sudah diestimasi perlu diuji secara signifikan terlebih dahulu guna mengevaluasi kecocokan model yang akan dipakai. Uji signifikansi dapat dilakukan menggunakan uji t-hitung.

$$T_{hitung} = \frac{\text{estimasi parameter}}{\text{standar error parameter}} \text{ dimana } SE(\text{parameter}) = \sqrt{\frac{1-(\text{parameter})^2}{n}} \tag{9}$$

Tabel 3. Daerah Estimasi Parameter

Proses	Daerah yang diterima	Estimasi awal
AR (1)	$-1 < \rho_1 < 1$	$\hat{\phi}_0 = \rho_1$
AR (2)	$-1 < \rho_2 < 1$ $\rho_1^2 < 0,5(\rho_2 + 1)$	$\hat{\phi}_{10} = \frac{\rho_1(1 - \rho_2)}{1 - \rho_1^2}$ $\hat{\phi}_{20} = \frac{(\rho_2 - \rho_1^2)}{1 - \rho_1^2}$
MA (1)	$-0,5 < \rho_1 < 0,5$	$\hat{\theta}_0 = \frac{1 - \sqrt{1 - \rho_1^2}}{2\rho_1}$
ARMA (1)	$2\rho_1 - \rho_1 < \rho_2 < \rho_1 $	$\hat{\phi}_0 = \frac{\rho_2}{\rho_1}$ $\hat{\theta}_0 = \frac{b + \sqrt{b^2 - 4}}{2}$ dengan $b = (1 - 2\rho_2 + \hat{\phi}_0^2)$

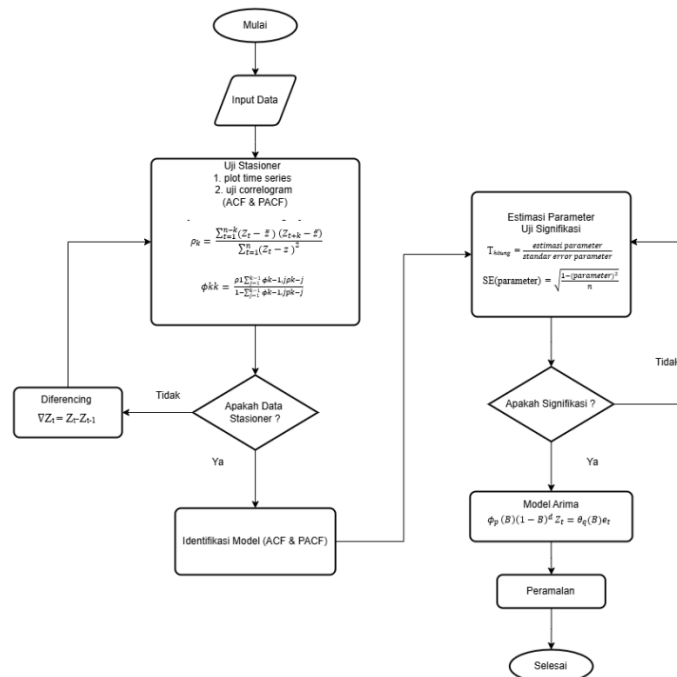
2.2.4 Estimasi Parameter dan Uji Signifikansi

Evaluasi parameter error berfungsi untuk mengevaluasi hasil prediksi yang didapatkan. Parameter yang digunakan dalam menguji error menggunakan MAPE (*Mean Absolute Percentage Error*) yang merupakan pengukuran persentase tingkat kesalahan pada nilai data sebenar [2]. Hasil dari MAPE juga dapat digunakan untuk melihat atau mengevaluasi ketepatan model yang digunakan dalam melakukan prediksi. Penggunaan MAPE sangat bermanfaat jika ukuran peramalan digunakan sebaifai faktor yang digunakan untuk menilai keakuratan peramalan dan memberikan gambaran seberapa besar selisih antara hasil peramalan dan nilai aktual dari data deret waktu yang dimodelkan [12]. Semakin kecil nilai sebuah MAPE maka dapat didefinisikan bahwa hasil prediksi yang digunakan akurat, dan begitupun sebaliknya. Untuk penjelasan lebih lanjut dapat dilihat pada tabel berikut:

Tabel 4. Rentang MAPE

MAPE	Keterangan
< 10%	Dikategorikan sangat baik
10% - 20%	Dikategorikan baik
20% - 50%	Dikategorikan cukup baik
>50%	Dikategorikan buruk

Adapun alur dari metode ARIMA pada penelitian ini pada gambar di berikut.



Gambar 4. Flowchart Metode ARIMA

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian Data Tahapan ARIMA

3.1.1 Uji Stasioner

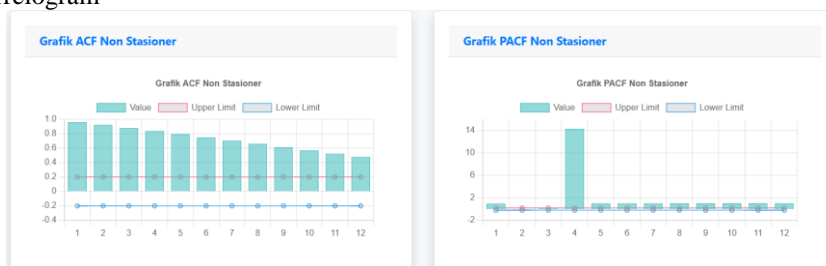
a) Uji Stasioner Metode Grafik

Jika dilihat pada gambar grafik (5) mengalami penurunan dan kenaikan yang tidak konsisten sehingga dari grafik tersebut menunjukkan bahwa data penduduk miskin tidak stasioner.



Gambar 5. Grafik Data Penduduk Miskin

b) Uji Correlogram



Gambar 6. Plot ACF dan PACF Non Stasioner

Hasil pengujian correlogram dengan plot ACF dan PACF menunjukkan bahwa data masih belum stasioner, seperti yang dapat dilihat pada gambar 6. Pada grafik autokorelasi atau ACF setiap lag mengalami penurunan secara bertahap menuju 0, sedangkan pada autokorelasi parsial terdapat lag dominan pada lag keempat dan hal tersebut menunjukkan data belum stasioner dengan nilai autokorelasi dan autokorelasi parsial pada tabel berikut.

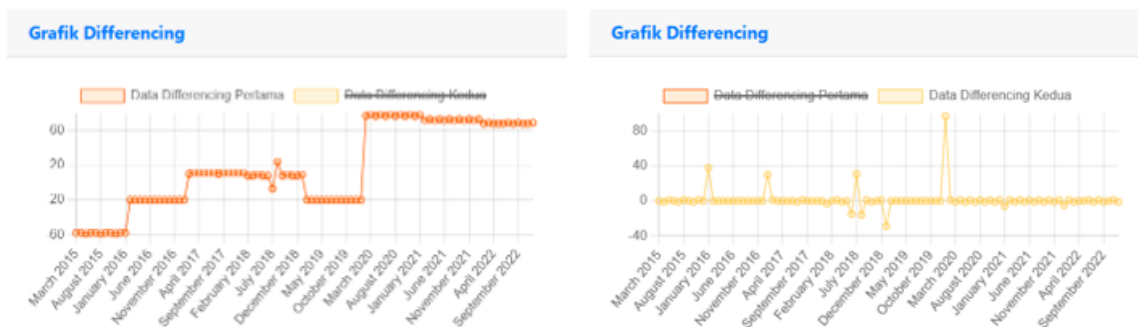
Tabel 5. Nilai ACF dan PACF Non Stasioner

lag	ACF Non Stasioner	PACF Non Stasioner
1.	0.96125	0.96125
2.	0.92097	-0.03987
3.	0.87939	0.21192
4.	0.83668	14.26632
5.	0.79300	1.01513
6.	0.74861	1.01792
7.	0.70367	1.02069
8.	0.65840	1.02346
9.	0.61296	1.02625
10.	0.56753	1.02907
11.	0.52232	1.03194
12.	0.47755	1.03486

3.1.2 Differencing dan Normalisasi

Tabel 6. Data Differencing dan Normalisasi

Bulan - Tahun	Data	Differencing Pertama	Differencing Kedua	Normalisasi
January 2015	19941	*	*	*
February 2015	19883	-58	*	*
March 2015	19825	-58	0	0.284
April 2015	19766	-59	-1	0.278
May 2015	19708	-58	1	0.29
June 2015	19650	-58	0	0.284
.
.
.
December 2022	21670	68	-1	0.27



Gambar 7. Grafik Hasil Differencing

Dilihat pada grafik 7 data differencing pertama menunjukkan bahwa data belum stasioner pada tahapan differencing pertama yang di tandai dari grafik yang masih menunjukkan adanya fluktuasi atau pola yang menunjukkan perubahan seperti lonjakan pada data yang mengindikasikan perubahan pada data sehingga data belum menunjukkan kestabilan. Data telah menjadi stasioner setelah melalui langkah-langkah diatas dan dapat dilihat pada gambar kedua pada gambar 7 (data differencing kedua), data telah menunjukkan tidak ada tren dan terdapat fluktuasi data yang berada disekitar nol dan menunjukkan data lebih stabil. Sedangkan fluktuasi lainnya dapat disebabkan adanya faktor lain seperti variasi acak pada data ataupun terdapat noise. Dengan nilai ACF dan PACF yang diperoleh pada tabel berikut.

Tabel 7. Nilai ACF dan PACF Stasioner

lag	ACF Stasioner	PACF Stasioner
1.	-0.07897	-0.07897
2.	0.00759	0.00137
3.	-0.01483	-0.01411
4.	-0.01598	-0.01832
5.	0.03103	0.02852
6.	-0.09327	-0.08821
7.	0.02765	0.01275
8.	-0.01506	-0.01046
9.	-0.00895	-0.01274
10.	-0.02154	-0.02671
11.	-0.00198	0.00005
12.	-0.17211	-0.18405

3.1.3 Differencing dan Normalisasi

Pada proses ini, akan dilakukan pengujian pada estimasi parameter serta uji signifikansi untuk melihat model yang diperoleh apakah sesuai dengan kriteria, dan hasil yang diperoleh dari estimasi serta uji signifikansi yang dapat diterima atau signifikansi hanya model AR(1) dengan nilai estimasi sebesar 0,079 dapat dilihat pada gambar 8. Dengan demikian model yang dapat diterapkan ARIMA (1,2,0), setelah mendapatkan model ARIMA tahapan selanjutnya melakukan perhitungan pada model dengan menggunakan data .Adapun hasil dari pengujian dapat dilihat pada gambar 9.

Estimasi Parameter dan Uji Signifikansi

Parameter	Estimasi	Signifikansi
AR(1)	0,079	Signifikan
AR(2)	$\phi_{10}:-0,079$ $\phi_{20}:-0,005$	Tidak Signifikan
MA(1)	-0,020	Tidak Signifikan

Gambar 8. Estimasi Parameter dan Uji Signifikansi

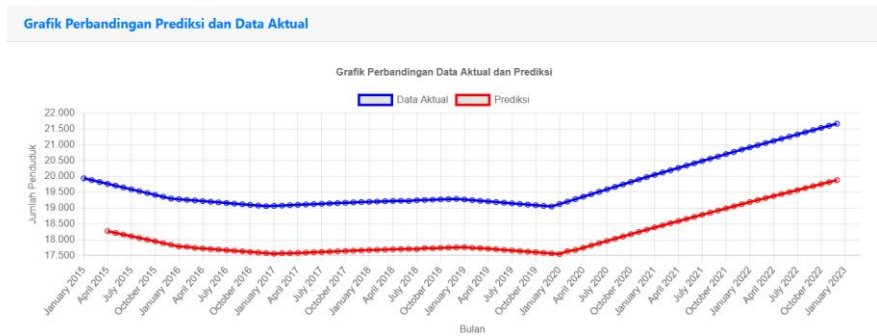
Hasil Prediksi Model ARIMA(1,2,0)
MAPE: 10,634%

No	Nilai Data	Prediksi ARIMA
1	19941	-
2	19883	-
3	19825	-
4	19766	18269
5	19708	18215
6	19650	18162
7	19591	18108
8	19533	18053

Gambar 9. Hasil Pengujian Model ARIMA

3.1.4 Prediksi

Dari model yang signifikansi, model ARIMA (1,2,0) telah menunjukkan bahwa model ini dapat digunakan dengan MAPE sebesar 10,6% serta pada tahap ini, akan dilakukan perbandingan antara data aktual jumlah penduduk miskin Kota Tanjungpinang dengan perbandingan hasil prediksi dapat dilihat pada gambar 10.



Gambar 10. Grafik Perbandingan Data Asli dan Prediksi

Berdasarkan gambar 10, grafik perbandingan antara data jumlah penduduk miskin Kota Tanjungpinang dengan data hasil prediksi memiliki pola yang mirip dengan data sebenarnya, dan cukup mampu menangkap pola pada data meski hasil prediksi cenderung memberikan estimasi yang lebih rendah daripada data sebenarnya. Dari hasil prediksi tersebut didapat nilai MAPE sebesar 10,6% yang menunjukkan hasil akurasi pada model ARIMA (1,2,0) dikategorikan baik. Dari model yang diperoleh dilakukan prediksi untuk bulan selanjutnya dan didapatkan pada tahun bulan Januari 2023 berkisar 18.302 ribu jiwa.

4. PENUTUP

Berdasarkan penerapan Autoregressive Integrated Moving Average (ARIMA) pada penelitian dalam memprediksi jumlah penduduk miskin Kota Tanjungpinang menghasilkan metode terbaik (1,2,0) dengan MAPE sebesar 10,6% yang menunjukkan bahwa hasil prediksi dikategorikan sangat baik, dengan prediksi untuk bulan January 2023 sebesar 18.302 ribu jiwa. Untuk pengembangan penelitian selanjutnya guna meningkatkan

kualitas model dan akurasi prediksi, disarankan untuk menambah dataset agar memperoleh gambaran yang lebih lengkap mengenai kemiskinan, sehingga model dapat memahami perubahan yang terjadi secara lebih baik dan meningkatkan akurasi prediksi. Selain itu, penggunaan atau penggabungan metode peramalan lain juga direkomendasikan untuk menangkap pola yang lebih kompleks, sehingga hasil prediksi menjadi lebih akurat serta mampu mengidentifikasi faktor-faktor yang memengaruhi jumlah penduduk miskin.

DAFTAR PUSTAKA

- [1] D. R. Rahadian and Nurmalitasari, "Analisis Kemiskinan Menggunakan Metode Algoritma Clustering K-Means," *Pros. Semin. Nas. Teknol. Inf. dan Bisnis*, pp. 25–28, 2023, [Online]. Available: <http://ojs.uadb.ac.id/index.php/Senatib/article/view/3000>
- [2] R. I. Prasetyono and D. Anggraini, "Analisis Peramalan Tingkat Kemiskinan Di Indonesia Dengan Model Arima," *J. Ilm. Inform. Komput.*, vol. 26, no. 2, pp. 95–110, 2021, doi: 10.35760/ik.2021.v26i2.3699.
- [3] W. Y. Rusyida, *Teknik Peramalan : Metode ARIMA dan Holt Winter*. 2022.
- [4] R. Ayu Wulandari and R. Gernowo, "Metode Autoregressive Integrated Moving Average (ARIMA) dan Metode Adaptive Neuro Fuzzy Inference System (ANFIS) dalam Analisis Curah Hujan," *Berk. Fis.*, vol. 22, no. 1, pp. 41–48, 2019.
- [5] A. Qalbi, K. Nurfadilah, and W. Alwi, "Comparison of Fuzzy Time Series Methods and Autoregressive Integrated Moving Average (ARIMA) for Inflation Data," *Eig. Math. J.*, vol. 4, no. 2, pp. 40–50, 2021, doi: 10.29303/emj.v4i2.122.
- [6] D. M. Putri and Aghsilni, "Estimasi Model Terbaik Untuk Peramalan Harga Saham PT. Polychem Indonesia Tbk Dengan Arima," *MAp J.*, vol. 1, no. 1, pp. 1–12, 2019.
- [7] D. Y. Perdana and M. A. I. Pakereng, "Prediksi Tingkat Pengangguran Berdasarkan Data Time Series Menggunakan Regresi Linear (Studi Kasus : Kota Salatiga)," *Jurnal EMT KITA*, vol. 6, no. 2, pp. 361–367, 2022. doi: 10.35870/emt.v6i2.702.
- [8] W. H. Lailiyah and D. Manuharawati, "Penerapan Metode Autoregressive Integrated Moving Average (Arima) pada Peramalan Nilai Ekspor Di Indonesia," *Ilm. Mat.*, vol. 6, no. 3, pp. 45–52, 2018.
- [9] F. D. Yuliantanti, D. C. R. Novitasari, N. Widodo, A. Hamid, and W. D. Utami, "Penerapan Metode Autoregressive Integrated Moving Average (Arima) Untuk Prediksi Bilangan Sunspot," *BAREKENG J. Ilmu Mat. dan Terap.*, vol. 15, no. 3, pp. 555–564, 2021, doi: 10.30598/barekengvol15iss3pp555-564.
- [10] A. F. Muzakki, D. Aditama, and I. Gita Anugrah, "Penerapan Metode Autoregressive Integrated Moving Average Untuk Memprediksi Penggunaan Barang Medis Pada Logistik Medis Rumah Sakit Muhammadiyah Gresik," *Indexia*, vol. 4, no. 1, p. 1, 2022, doi: 10.30587/indexia.v4i1.3595.
- [11] R. Yuliyanti and E. Arliani, "Peramalan Jumlah Penduduk Menggunakan Model ARIMA," *Kaji dan Terap. Mat.*, vol. 8, no. 2, pp. 114–128, 2022.
- [12] T. Indayani and M. Y. Darsyah, "Pemilihan Model Peramalan Terbaik Menggunakan Model Arima dan Winters Untuk Meramalkan Indeks LQ45," *Pros. Semin. Nas. Mhs. Unimus*, vol. 1, pp. 336–342, 2018.