

*Corresponding author: Muhammad Nusran, Department of Statistics, Universitas Negeri Makassar, Makassar, Indonesia

E-mail: muh.nusrang@unm.ac.id

RESEARCH ARTICLE

Analysis of Rice Production Forecast in Maros District Using the Box-Jenkins Method with the ARIMA Model

Sulaeman Nurman, Muhammad Nusrang*, Sudarmin

Department of Statistics, Universitas Negeri Makassar, Makassar, Indonesia

Abstract: The Box-Jenkins method is a statistical method used for forecasting time series data. This method uses data in the past as the dependent variable. The data used in this study is data on the amount of rice production in Maros Regency which was taken from 2001 to 2018 which was taken from the Central Statistics Agency of Maros Regency and the Department of Food Security, Food Crops, and Horticulture of South Sulawesi Province. The results obtained show that the ARIMA(0,2,1) model is a suitable model to predict the amount of rice production in Maros Regency. Forecasting results show that the amount of rice production in Maros Regency has increased every year with an average increase of 3807.1 tons.

Keywords: ARIMA, Box-Jenkins, Rice Production.

1. Introduction

Beras merupakan suatu kebutuhan pokok masyarakat sehari-hari. Sebagian besar penduduk Indonesia mengonsumsi beras sebagai makanan pokok, terutama di Kabupaten Maros. Semakin banyak orang yang mengonsumsi beras maka kebutuhan beras juga akan semakin tinggi.

Laju pertumbuhan penduduk di Kabupaten Maros adalah sebesar 0,99 persen (Badan Pusat Statistik Kabupaten Maros, 2019) memungkinkan akan membutuhkan jumlah pangan yang banyak untuk memenuhi kebutuhan secara merata. Oleh karena itu, peneliti akan melakukan peramalan atau prakiraan produksi beras di Kabupaten Maros.

Peramalan adalah perkiraan atau prediksi tentang sesuatu yang akan terjadi pada waktu yang akan datang dengan menggunakan data masa lalu. Salah satu cara untuk melakukan peramalan adalah menggunakan analisis deret waktu (*time series*).

Metode Box-Jenkins atau sering disebut metode ARIMA meramalkan data time series berdasarkan pada teori statistik yang telah berkembang untuk menemukan pola dalam deret data lalu mengekstrapolasikannya ke masa depan (Suseno, 2017). Model ARIMA merupakan model peramalan yang menghasilkan ramalan-ramalan berdasarkan sintesis dari pola data secara historis. Dalam membuat peramalan model ARIMA tidak menggunakan variabel independen tetapi menggunakan nilai-nilai sekarang dan nilai-nilai lampau dari variabel dependen untuk menghasilkan peramalan jangka pendek yang akurat (Nurjanah, et.al., 2018)

Penggunaan teknik Box-Jenkins dalam suatu prediksi atau forecasting data berbeda dengan metode forecasting yang lain. Teknik ini tidak mengasumsikan adanya pemecahan (decomposition) yang berbentuk pola-pola khusus: tren, siklus, musim, dan perubahan tak tentu (irregular) pada data runtun waktu (Setiasih & Priyono, 2009). Oleh karena itu, dalam



penelitian ini akan digunakan metode Box-Jenkins dengan model ARIMA untuk meramalkan produksi beras di Kabupaten Maros.

2. Literature Review

2.1. Analisis Deret Waktu (*time series*)

Analisis deret waktu (*time series*) merupakan serangkaian data pengamatan yang terjadi berdasarkan indeks waktu secara berurutan dengan interval waktu tetap. Analisis deret waktu adalah salah satu prosedur statistika yang diterapkan untuk meramalkan struktur probabilistik keadaan yang akan terjadi di masa yang akan datang dalam rangka pengambilan keputusan (Aswi & Sukarna, 2006).

2.2. Jenis Pola Data

Analisis data dapat dibedakan menjadi empat jenis, yaitu pola musiman, siklis, *trend*, dan *irregular*. Pola musiman merupakan fluktuasi dari data yang terjadi secara periodik dalam kurun waktu satu tahun, seperti triwulan, kuartalan, bulanan, mingguan, atau harian. Pola siklis terjadi apabila datanya dipengaruhi oleh fluktuasi ekonomi jangka panjang, seperti yang berhubungan dengan siklus bisnis. Pola *trend* merupakan kecenderungan arah data dalam jangka panjang, dapat berupa kenaikan maupun penurunan. Sedangkan pola *irregular* merupakan kejadian yang tidak terduga bersifat acak, tetapi kemunculannya dapat mempengaruhi fluktuasi data *time series* (Ukhra, 2014).

2.3. Stasioneritas

Ciri-ciri dalam pembentukan model analisis deret waktu adalah dengan mengasumsikan bahwa data dalam keadaan stasioner. Deret waktu dikatakan stasioner jika tidak ada perubahan kecenderungan dalam rata-rata dan perubahan variansi. Secara sederhana, konsep stasioner dapat diartikan suatu kondisi dimana nilai suatu data tidak jauh berbeda atau mungkin sama dengan data yang lainnya (Aswi & Sukarna, 2006).

2.4. Transformasi Box-Cox

Transformasi Box-Cox adalah salah satu metode yang digunakan untuk menstasionerkan data yang tidak stasioner dalam variansi. Secara matematis, transformasi Box-Cox dirumuskan sebagai berikut:

$$Z_t^{(\lambda)} = \frac{Z_t^{(\lambda)} - 1}{\lambda} \quad (1)$$

dimana λ sebagai parameter transformasi. Setiap nilai λ memiliki rumus transformasi yang berbeda. Berikut ini adalah nilai λ beserta rumus transformasinya.

Tabel 1. Nilai λ dan transformasinya

λ	Transformasi
-1	$\frac{1}{Z_t}$
-0,5	$\frac{1}{\sqrt{Z_t}}$
0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1	Z_t

(Aswi & Sukarna, 2006)

Aswi dan Sukarna (2006), Beberapa ketentuan untuk menstabilkan variansi adalah:

- (1) Transformasi boleh dilakukan hanya untuk deret Z_t yang positif.
- (2) Transformasi dilakukan sebelum melakukan *differencing* dan pemodelan *time series*.

- (3) Transformasi tidak hanya menstabilkan variansi, tetapi juga dapat menormalkan distribusi.

2.5. Differencing

Differencing merupakan metode yang dilakukan untuk menstasionerkan data yang tidak stasioner dalam rata-rata. *Differencing* adalah selisih antara data ke- t dengan data ke- $t-1$. Bentuk *differencing* untuk orde pertama yaitu:

$$\Delta Z_t = Z_t - Z_{t-1} \tag{2}$$

Adapun Bentuk *differencing* untuk orde kedua yaitu:

$$\begin{aligned} \Delta^2 Z_t &= \Delta Z_t - Z_{t-1} = (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) \\ &= Z_t - 2Z_{t-1} + Z_{t-2} \end{aligned} \tag{3}$$

2.6. Uji Augmented Dickey Fuller Test (ADF)

Uji ADF merupakan pengembangan versi pengujian Dickey Fuller. Uji ADF adalah salah satu metode yang digunakan untuk memastikan bahwa data sudah stasioner. Uji ADF bertujuan untuk mengetahui apakah data mengandung unit *roots* atau tidak. Jika data mengandung unit *roots* maka data yang digunakan belum stasioner. Apabila hasil uji ADF menunjukkan belum stasioner, maka harus dilakukan proses *differencing*. Adapun rumus uji ADF sebagai berikut:

$$\Delta Z_t = \gamma Z_{t-1} + \sum_{i=2}^p \alpha_i \Delta^2 Z_{t-1+i} + a_t \tag{4}$$

$$\Delta Z_t = \beta + \gamma Z_{t-1} + \sum_{i=2}^p \alpha_i \Delta^2 Z_{t-1+i} + a_t \tag{5}$$

$$\Delta Z_t = \beta_1 + \beta_2 T + \gamma Z_{t-1} + \sum_{i=2}^p \alpha_i \Delta^2 Z_{t-1+i} + a_t \tag{6}$$

2.7. Fungsi Autokorelasi (ACF)

Koefisien autokorelasi adalah suatu fungsi yang menunjukkan besarnya korelasi antara pengamatan pada waktu ke- t (dinotasikan dengan Z_t) dengan pengamatan pada waktu-waktu sebelumnya (dinotasikan dengan $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k}$). Koefisien autokorelasi untuk lag k dinyatakan sebagai berikut:

$$r_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z}_t)(Z_{t+k} - \bar{Z}_t)}{\sum_{t=1}^{n-k} (Z_t - \bar{Z}_t)^2} \tag{7}$$

Karena r_k merupakan fungsi atas k , maka hubungan koefisien autokorelasi dengan lagnya disebut dengan fungsi autokorelasi.

2.8. Fungsi Autokorelasi Parsial (PACF)

Fungsi autokorelasi parsial (PACF) adalah suatu fungsi yang menunjukkan besarnya korelasi parsial antara pengamatan pada waktu ke- t (dinotasikan dengan Z_t) dengan pengamatan pada waktu-waktu sebelumnya (dinotasikan dengan $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k}$). Rumus autokorelasi parsial atau ϕ_{kk} yaitu:

$$\phi_{kk} = \text{corr} (Z_t, Z_{t-k} | Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}) \quad (8)$$

2.9. Model-model Analisis Deret Waktu

a) Model AR

Deret waktu Z_t merupakan suatu proses AR (*Autoregressive*) berorde p atau AR (p) dapat dinyatakan sebagai:

$$\begin{aligned} Z_t &= \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \\ (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t &= a_t \\ \phi_p(B) Z_t &= a_t \end{aligned} \quad (9)$$

Dengan kata lain, Z_t merupakan kombinasi linier p buah nilai-nilai sebelumnya ditambah dengan galat pada saat t . Peubah galat a_t diasumsikan saling bebas terhadap $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$ dan berdistribusi normal dengan rata-rata nol dan variansi σ^2 .

b) Model MA

Model MA (*Moving Average*) berorde q merupakan suatu deret Z_t yang terbentuk dari galat pada waktu t dan galat-galat pada waktu sebelumnya yang diberi bobot, sehingga dapat dinyatakan sebagai berikut:

$$\begin{aligned} Z_t &= a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \\ Z_t &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \\ Z_t &= \theta_q(B) a_t \end{aligned} \quad (10)$$

c) Model ARMA

Model ARMA (*Auto Regressive Moving Average*) berorde p dan q merupakan proses deret waktu yang dibangun dari penggabungan antara AR (p) dan MA (q) dengan bentuk persamaan:

$$\begin{aligned} \phi_p(B) Z_t &= \theta_q(B) a_t \\ (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \\ Z_t &= \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \end{aligned} \quad (11)$$

d) Model ARIMA

Model ARIMA dilakukan pada data yang didifferencing sehingga data telah stasioner. Model ARIMA (p, d, q) merupakan gabungan dari model ARMA (p, q) dan proses differencing, yaitu:

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B) a_t \quad (12)$$

2.10. Akaike's Information Criterion (AIC)

Akaike's Information Criterion (AIC) adalah salah satu kriteria pemilihan model terbaik yang diperkenalkan oleh Akaike pada tahun 1973. Persamaan AIC dalam pemilihan model terbaik sebagai berikut:

$$AIC = n \times \ln \left(\frac{SSE}{n} \right) + 2f + n + n \times \ln (2\pi) \quad (13)$$

dimana :

- ln = natural log
- SSE = Sum Square Error
- n = banyaknya pengamatan
- f = banyaknya parameter dalam model
- π = 3,14

Model dikatakan baik untuk digunakan jika nilai AIC yang diperoleh semakin kecil.

2.11. Metode Box-Jenkins

Autoregressive integrated moving average (ARIMA) biasanya sering disebut metode Box-Jenkins. Model *autoregressive integrated moving average* (ARIMA) telah dipelajari secara mendalam oleh George Box dan Gwilym Jenkins, dan nama mereka sering disinonimkan dengan proses ARIMA yang diterapkan untuk analisis runtun waktu, peramalan dan pengendalian (Samsiah, 2008).

Metode peramalan yang telah dikenalkan oleh George Box dan Gwilym Jenkins adalah metode Box-Jenkins. Langkah-langkah dalam peramalan dengan menggunakan metode Box-Jenkins, dapat dilakukan dengan identifikasi model, penaksiran parameter, pemeriksaan diagnostik, dan peramalan (Desvina & Syahfitra, 2016).

a) Identifikasi model

Tahap untuk melakukan identifikasi model sementara yaitu menentukan deret waktu yang digunakan untuk peramalan stasioner atau tidak. Hal ini sangat penting karena model-model ini hanya berlaku untuk data stasioner. Jika data tidak stasioner maka dilakukan *differencing* atau transformasi. Setelah data stasioner selanjutnya yaitu melihat plot ACF dan PACF untuk menduga orde AR dan MA yang sesuai.

b) Estimasi parameter model

Setelah melakukan identifikasi model sementara, tahap selanjutnya yaitu mengestimasi nilai nilai parameter model dan menguji signifikansi dari parameter model tersebut.

c) Diagnosis model atau tahap verifikasi

Diagnosis model dilakukan untuk menguji apakah model yang dibangun layak untuk digunakan dalam peramalan. Model dikatakan layak jika asumsi dari *error* memenuhi proses *white noise* dan berdistribusi normal.

d) Peramalan

Untuk langkah yang terakhir yaitu peramalan untuk masa yang akan datang berdasarkan data pada masa lalu atau data sebelumnya.

3. Research Method

3.1. Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang bersumber dari Badan Pusat Statistik Kabupaten Maros dan Dinas Ketahanan Pangan, Tanaman Pangan, dan Hortikultura Provinsi Sulawesi Selatan. Data yang digunakan yaitu data produksi padi di Kabupaten Maros tahun 2001 – 2018.

3.2. Definisi Operasional Peubah

Variabel penelitian yang digunakan yaitu jumlah produksi beras di Kabupaten Maros.

3.3. Teknik Analisis

Adapun teknik analisis data yang dilakukan dalam penelitian ini yaitu sebagai berikut:

a) Analisis Deskriptif.

Analisis Deskriptif dilakukan untuk mengetahui deskriptif data penelitian, selain itu juga untuk mengetahui pola dari data penelitian.

b) Analisis menggunakan ARIMA Box-Jenkins.

Tahapan-tahapan dalam melakukan analisis menggunakan ARIMA Box-Jenkins adalah dengan membuat plot *time series* dan plot ACF untuk mengetahui stasioneritas data baik dalam rata-rata maupun variansi. Jika data tidak stasioner dalam rata-rata, maka dilakukan

differencing, dan jika tidak stasioner dalam variansi dilakukan transformasi Box-Cox. Setelah data stasioner, tahap selanjutnya adalah menduga model beberapa ARIMA berdasarkan plot ACF dan PACF. Setelah itu dilakukan uji parameter model, serta melakukan pengujian asumsi residual, yaitu asumsi residual *white noise* dengan uji Ljung-Box dan menguji asumsi residual berdistribusi normal dengan uji Kolomogorov Smirnov. Tahapan pemodelan ARIMA, sebagai berikut:

(1) *Identifikasi Model*

Identifikasi model bertujuan untuk melihat apakah data stasioner atau tidak. Jika tidak stasioner maka dilakukan proses *differencing*/transformasi terlebih dahulu. Setelah data stasioner selanjutnya yaitu melihat plot ACF dan PACF untuk menduga orde AR dan MA yang sesuai.

(2) *Estimasi Parameter*

Estimasi parameter dilakukan dengan menggunakan *software* R. Uji Hipotesis juga dilakukan untuk mengetahui signifikansi sebuah parameter.

H_0 : Parameter = 0

H_1 : Parameter \neq 0

(3) *Verifikasi Model*

Pengujian kelayakan model dapat dilakukan dengan beberapa cara yaitu:

- (a) *Overfitting* dilakukan apabila diperlukan model yang lebih luas.
- (b) Menguji residual (*error term*). Secara sistematis residual dapat dihitung dengan cara mengurangi data hasil ramalan dengan data asli. Pemilihan model dalam metode ARIMA dilakukan dengan mengamati distribusi koefisien autokorelasi dan koefisien autokorelasi parsial.

1) Koefisien Autokorelasi

Koefisien korelasi menunjukkan arah dan keamatan hubungan dua variasi sehingga menggambarkan apa yang terjadi pada satu variabel bila terjadi perubahan pada variabel yang lain. Suatu koefisien autokorelasi disimpulkan tidak berbeda secara signifikan dari nol apabila nilainya terletak di antara rentang nilai tersebut dan sebaliknya.

2) Autokorelasi Parsial

Koefisien autokorelasi parsial mengukur tingkat keamatan hubungan antara X_t dengan X_{t-k} , sedangkan pengaruh dari *time lag* 1, 2, 3, dan seterusnya sampai k-1 dianggap konstan.

(4) *Peramalan*

Langkah terakhir yaitu melakukan peramalan dengan menggunakan model yang terpilih.

4. Results and Discussion

4.1. Deskripsi Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder, yaitu data jumlah produksi padi di Kabupaten Maros dari tahun 2001 – 2018. Data tersebut dikonversi menjadi beras karena tujuan penelitian ini yaitu untuk mengetahui hasil peramalan produksi beras di Kabupaten Maros. Angka konversi Gabah Kering Panen (GKP) ke Gabah Kering Giling (GKG) adalah sebesar 83,38 persen, dan angka konversi GKG ke beras adalah sebesar 64,02 persen (Badan Pusat Statistik, 2018). Bentuk produksi dari padi yaitu Gabah Kering Giling yang artinya data akan dikonversi sebesar 64,02 persen.

4.2. Analisis Deskriptif

Analisis deksriptif bertujuan untuk menggambarkan atau mendeskripsikan variabel penelitian yang dilihat dari jumlah data, nilai maksimum, nilai minimum, nilai rata-rata, dan standar deviasi.

Tabel 1. Statistik Deskriptif


Variabel	N	Min	Max	Mean	Std. Deviation
Produksi	18	136503	224818	167157	26830

Dari tabel 1 dapat disimpulkan bahwa data yang digunakan dalam analisis yaitu sebanyak 18 tahun. Standar deviasi untuk data jumlah produksi beras di Kabupaten Maros yaitu sebesar 26830 ton. Jumlah produksi beras yang paling sedikit yaitu 136503 ton, sedangkan jumlah produksi beras yang paling banyak yaitu 224818 ton. Rata-rata jumlah produksi beras di Kabupaten Maros dari tahun 2001 sampai dengan tahun 2018 yaitu sebesar 167157 ton.

4.3. Analisis Menggunakan ARIMA Box-Jenkins


4.3.1. Plot Data

Langkah pertama yang harus dilakukan adalah membuat plot data. Dalam hal ini adalah membuat plot data produksi beras dengan menggunakan *software R*.




Gambar 1. Plot Data Jumlah Produksi Beras di Kabupaten Maros

Berdasarkan gambar 1 dapat dilihat bahwa plot produksi beras cenderung mengalami peningkatan artinya data tidak stasioner dalam rata-rata sehingga perlu dilakukan *differencing*.




Gambar 2. Plot ACF Data Jumlah Produksi Beras di Kabupaten Maros

Berdasarkan gambar 2 dapat dilihat bahwa data jumlah produksi beras tidak stasioner dalam rata-rata, karena pada plot ACF menurun secara lambat atau mengecil secara bertahap yang artinya data tidak stasioner. Kestasioneran data juga dapat dilihat menggunakan *Augmented Dickey-Fuller Test*. Dari hasil analisis diperoleh nilai $p\text{-value} = 0,07434$ lebih besar dari nilai $\alpha = 0,05$ artinya data tidak stasioner sehingga perlu dilakukan *differencing*.



Gambar 3. Plot Data Jumlah Produksi Beras di Kabupaten Maros setelah *differencing* Pertama

Berdasarkan gambar 3 dapat dilihat bahwa plot produksi beras setelah *differencing* pertama tidak cenderung mengalami peningkatan artinya data sudah stasioner. Kestasioneran data juga dapat dilihat menggunakan *Augmented Dickey-Fuller Test*. Dari hasil analisis diperoleh nilai $p\text{-value} = 0,0107$ lebih kecil dari nilai $\alpha = 0,05$ artinya data sudah stasioner.




Gambar 4. Plot ACF Data Jumlah Produksi Beras di Kabupaten Maros setelah *differencing* Pertama


Berdasarkan gambar 4 dapat dilihat bahwa data jumlah produksi beras setelah *differencing* pertama sudah stasioner, karena plot ACF pada lag pertama mengalami *cut off* sedangkan lag lainnya berada di dalam batas signifikan dan juga tidak menurun secara lambat artinya data sudah stasioner.

4.3.2. Identifikasi Model

Setelah diketahui bahwa data telah stasioner, langkah selanjutnya yaitu identifikasi untuk mendapatkan model ARIMA. Identifikasi yang dilakukan dengan melihat plot *Autocorrelation Function* (ACF) dan plot *Partial Autocorrelation Function* (PACF) dari data.




Gambar 5. Plot ACF Data Jumlah Produksi Beras di Kabupaten Maros setelah differencing Pertama




Gambar 6. Plot PACF Data Jumlah Produksi Beras di Kabupaten Maros setelah differencing Pertama

Berdasarkan identifikasi pada gambar 5 dan gambar 6 terlihat bahwa plot ACF mengalami cut off pada lag pertama, dan pada plot PACF mengalami pola dies down, sehingga diperoleh satu model yaitu ARIMA (0, 1, 1) artinya tidak dapat memilih model terbaik karena hanya ada satu model yang diperoleh sehingga dilakukan differencing kedua agar lebih banyak model yang diperoleh.



Gambar 7. Plot ACF Data Jumlah Produksi Beras di Kabupaten Maros setelah differencing Kedua



Gambar 8. Plot PACF Data Jumlah Produksi Beras di Kabupaten Maros setelah differencing Kedua

Berdasarkan identifikasi pada gambar 7 dan 8 terlihat bahwa plot ACF mengalami cut off pada lag pertama, dan pada plot PACF mengalami pola cut off pada lag ketiga, artinya model dugaan tertinggi untuk AR = 3 dan MA = 1 sehingga diperoleh beberapa model sebagai berikut.

Tabel 2. Model ARIMA untuk Produksi Beras di Kabupaten Maros

Model	AIC
ARIMA (3, 2, 1)	369,17
ARIMA (2, 2, 1)	370,48
ARIMA (1, 2, 1)	369,97
ARIMA (0, 2, 1)	368,12
ARIMA (3, 2, 0)	-
ARIMA (2, 2, 0)	375,62
ARIMA (1, 2, 0)	375,45

Dari tabel 2 dapat diketahui bahwa model ARIMA (0, 2, 1) merupakan model terbaik dengan melihat nilai AIC yaitu sebesar 368,12 untuk data jumlah produksi beras di Kabupaten Maros.

4.3.3. Penaksiran dan Uji Signifikansi Parameter

Setelah didapatkan model terbaik selanjutnya dilakukan penaksiran dan pengujian signifikansi parameter. Penaksiran dan pengujian parameter dilakukan untuk memperoleh nilai dari parameter model ARIMA terpilih yang signifikan dengan parameter θ untuk model ARIMA (0, 2, 1). Uji kesignifikan parameter dilakukan menggunakan uji t dengan hipotesis sebagai berikut.

H_0 : Parameter tidak signifikan

H_1 : Parameter signifikan

Hasil penaksiran dan pengujian parameter untuk model ARIMA (0, 2, 1) sebagai berikut :

Tabel 3. Hasil penaksiran dan pengujian parameter untuk model ARIMA (0, 2, 1)

Model ARIMA	Parameter	t_{hitung}	P -value	Keputusan
ARIMA (0, 2, 1)	θ	2,80	0,014	Signifikan

Dari tabel 3 dapat dilihat bahwa nilai t sebesar 2,80 dan p -value sebesar 0,014. Tolak H_0 jika p -value $< \alpha$, maka diperoleh nilai $< 0,05$ sehingga dapat disimpulkan bahwa parameter θ untuk model ARIMA (0, 2, 1) signifikan.

4.3.4. Uji Kesesuaian Model

Setelah uji parameter selanjutnya dilakukan uji kesesuaian model, meliputi uji asumsi residual *white noise* dan uji asumsi residual berdistribusi normal. Pengujian *white noise* dilakukan dengan menggunakan uji *Ljung-Box* dengan hipotesis berikut.

H0 : model memenuhi syarat cukup

H1 : model belum memenuhi syarat cukup

Berikut hasil pengujian asumsi residual white noise untuk model ARIMA (0, 2, 1)

Tabel 4. Hasil pengujian asumsi *white noise* Model ARIMA (0, 2, 1)

Lags	Statistik Q	df	X^2_{tabel}	p -value
1	0,5387037	1	3,841	0,4629704
2	2,9415564	2	5,991	0,2297466
3	4,8264958	3	7,815	0,1849519
4	5,3440764	4	9,488	0,2537790
5	7,1453688	5	11,070	0,2100516
6	7,1581512	6	12,592	0,3064689
7	8,3452259	7	14,067	0,3031385
8	8,3650933	8	15,507	0,3986432
9	8,4352103	9	16,919	0,4909507
10	8,5330064	10	18,307	0,5769198

Tolak H_0 jika $Q > X^2_{\alpha;df}$. Berdasarkan tabel 4 untuk pengujian asumsi residual *white noise* model dugaan ARIMA (0, 2, 1), diperoleh bahwa dari 10 lag yang diuji, yaitu dari lag-1 sampai lag-10 didapat semua nilai statistik uji (Q) kurang dari nilai X^2_{tabel} dan nilai p -value $> \alpha$. Hal ini berarti gagal menolak hipotesis H_0 sehingga model ARIMA (0, 2, 1) telah memenuhi uji asumsi *white noise*. Setelah pengujian asumsi residual, selanjutnya dilakukan pengujian residual berdistribusi normal dengan menggunakan *Kolmogorov-Smirnov* dengan hipotesis sebagai berikut.

H0 : Residual berdistribusi normal

H1 : Residual tidak berdistribusi normal

Berikut hasil pengujian residual berdistribusi normal untuk model dugaan ARIMA (0, 2, 1).

Tabel 5. Hasil Uji Residual Berdistribusi Normal Model ARIMA (0, 2, 1)

<i>Kolmogorov Smirnov</i>	p -value
0,19064	0,08277

Hasil pengujian untuk uji residual berdistribusi normal model ARIMA (0, 2, 1) diperoleh p -value lebih besar dari α yaitu sebesar $0,08277 > 0,05$ yang berarti gagal tolak H_0 sehingga dapat dikatakan bahwa residual model ARIMA (0, 2, 1) berdistribusi normal. Model ARIMA tersebut dapat dijabarkan sebagai berikut :

$$(1 - B)^d Z_t = \theta_q(B) a_t$$

$$(1 - B)^2 Z_t = (1 - \theta_1 B) a_t \quad ; \theta_1 = 0,9$$

$$(1 - B)^2 Z_t = (1 - 0,9B) a_t$$

$$(1 - 2B + B^2) Z_t = (1 - 0,9B) a_t$$

$$Z_t - 2BZ_t + B^2Z_t = a_t - 0,9Ba_t$$

$$Z_t - 2Z_{t-1} + Z_{t-2} = a_t - 0,9a_{t-1}$$

$$Z_t = 2Z_{t-1} - Z_{t-2} + a_t - 0,9a_{t-1}$$

Tahap selanjutnya dapat dilanjutkan ketika parameter model signifikan dan seluruh asumsi telah terpenuhi.


4.3.5. Peramalan

Langkah terakhir dalam analisis deret waktu adalah menentukan peramalan atau prakiraan untuk periode selanjutnya. Peramalan atau prakiraan jumlah produksi beras di Kabupaten Maros untuk beberapa tahun ke depan dengan menggunakan ARIMA (0, 2, 1) sebagai berikut.

Tabel 6. Hasil Peramalan jumlah produksi beras di Kabupaten Maros

Tahun	Produksi (Ton)
2019	213672,1
2020	217479,3
2021	221286,4
2022	225093,6
2023	228900,7
2024	232707,9
2025	236515,0
2026	240322,1
2027	244129,3
2028	247936,4

Dari Tabel 6 dapat dilihat bahwa secara deskriptif jumlah produksi beras di Kabupaten Maros untuk tahun 2019 sampai dengan tahun 2028 mengalami peningkatan setiap tahunnya.



Gambar 9. Plot Data Jumlah Produksi Beras di Kabupaten Maros beserta Hasil Ramalannya menggunakan model ARIMA (0,2,1).

5. Conclusion

Berdasarkan hasil dari penelitian yang dilakukan dapat disimpulkan bahwa:

- 1) Hasil analisis dengan menggunakan metode Box-Jenkins model ARIMA untuk data jumlah produksi beras di Kabupaten Maros, diperoleh model terbaik dengan melihat

- nilai AIC paling kecil yaitu model ARIMA (0, 2, 1) dengan nilai AIC sebesar 368,12.
- 2) Hasil peramalan jumlah produksi beras di Kabupaten Maros menggunakan model ARIMA (0, 2, 1) mengalami peningkatan setiap tahunnya dengan rata-rata peningkatan yaitu sebesar 3807,1 ton.

References

- Aswi & Sukarna (2006). *Analisis Deret Waktu: Teori dan Aplikasi*. Makassar : Andira Publisher.
- Badan Pusat Statistik (2018). *SKGB 2018 Konversi Gabah ke Beras*. Jakarta : PT Citra Mawana Patamaro.
- Badan Pusat Statistik (2019). *Kabupaten Maros Dalam Angka 2019*. Maros : Media Art Design.
- Desvina, A. P., & Syahfitra, M. (2016). Aplikasi Metode Box-Jenkins dalam Memprediksi Pertumbuhan Perdagangan Luar Negeri Provinsi Riau. *Jurnal Sains Matematika dan Statistika*, Vol. 2 No. 2 Juli 2016.
- Nurjanah, I. S., Ruhiat, D., & Andiani, D. (2018). Implementasi Model Autoregressive Integrated Moving Average (ARIMA) untuk Peramalan Jumlah Penumpang Kereta Api di Pulau Sumatera. *Jurnal Teorema: Teori dan Riset Matematika* Vol 3 No 2, Hal 145-156, September 2018.
- Samsiah, D. N. (2008). *Analisis Data Runtun Waktu Menggunakan Model ARIMA (p,d,q)*. Skripsi. UIN Sunan Kalijaga Yogyakarta.
- Setiasih, E. & Priyono, R. (2009). Peramalan Inflasi di Wilayah Purwokerto dengan Metodologi Box-Jenkins. *Jurnal Eko-Regional Pembangunan Ekonomi Wilayah*, Vol. 4, No. 1, Maret 2009.
- Suseno, S. W. (2017). *Penerapan Metode ARIMA Box-Jenkins Untuk Peramalan Pasien Rawat Jalan di RSUD Kartini Kabupaten Jepara Berbantuan E-views*. Tugas Akhir. Universitas Negeri Semarang.
- Ukhra, A. U. (2014). Pemodelan dan Peramalan Data Deret Waktu dengan Metode Seasonal ARIMA. *Jurnal Matematika UNAND*, Vol. 3 No. 3 Hal. 59-67.