

## PERBANDINGAN METODE UNTUK MEMPREDIKSI LUAS PANEN PADI DI INDONESIA

Elok Indana Zulfa<sup>1</sup>, Noviati Maharani Sunariadi<sup>2</sup>, Hani Khaulasari<sup>3</sup>

<sup>1</sup> UIN Sunan Ampel Surabaya, [elok1508@gmail.com](mailto:elok1508@gmail.com)

<sup>2</sup> UIN Sunan Ampel Surabaya, [noviati.ms28@gmail.com](mailto:noviati.ms28@gmail.com)

<sup>3</sup> UIN Sunan Ampel Surabaya, [hani.khaulasari@uinsby.ac.id](mailto:hani.khaulasari@uinsby.ac.id)

**Abstrak:** Bagi Sebagian masyarakat Indonesia Padi adalah sebagai bahan karbohidrat utama. Indonesia termasuk dalam negara penghasil padi terbesar ketiga di dunia. Hal tersebut terlihat karena banyaknya lahan yang cocok untuk dijadikan lahan pertanian karena Indonesia memiliki tanah yang subur. Oleh karena itu penting untuk mengetahui jumlah padi untuhantisipasi di bulan selanjutnya. Maka dilakukan perbandingan model terbaik menggunakan metode *single exponential smoothing*, ARIMA outlier, dan Multilayer Perceptron. Pada penelitian ini didapatkan model terbaik untuk melakukan peramalan padi di Indonesia adalah dengan metode Multilayer Perceptron dengan nilai error MAPE yang didapat adalah 0,89%.

**Kata Kunci :** ARIMA outlier, Multilayer Perceptron, Peramalan, Single Exponential Smoothing

**Abstract:** For some Indonesian people, rice is the main carbohydrate ingredient. Indonesia is included in the third largest rice producing country in the world. This can be seen because there is a lot of land suitable for agriculture because Indonesia has fertile soil. Therefore it is important to know the amount of rice to anticipate in the following month. Then the comparison of the best models using the single exponential smoothing, ARIMA outlier, and Multilayer Perceptron methods is carried out. In this study, the best model for forecasting rice in Indonesia is the Multilayer Perceptron method with the MAPE error value obtained is 0,89%.

**Keywords:** ARIMA outlier, Multilayer Perceptron, Forecasting, Single Exponential Smoothing

### 1. Pendahuluan

Padi merupakan tanaman penghasil beras yang sampai saat ini masih diandalkan di banyak negara sebagai karbohidrat utama yang dikonsumsi oleh manusia. Khususnya untuk sebagian masyarakat Indonesia, selain berfungsi sebagai karbohidrat utama, padi juga berperan sebagai sumber mata pencaharian [1]. Indonesia termasuk dalam negara penghasil padi terbesar ketiga di dunia. Hal tersebut terlihat karena banyak lahan kosong yang cocok untuk dijadikan lahan pertanian karena Indonesia memiliki tanah yang subur [2]. Jenis tanaman yang ditanam dan tumbuh di lahan pertanian sangat beragam, tapi pada umumnya yang ditanam adalah padi [3].

Di Indonesia, luas panen padi sering mengalami kenaikan dan penurunan. Hal tersebut disebabkan karena faktor curah hujan, kecepatan angin, serta suhu. Jika luas panen terus menurun, produksi padi juga akan menurun dan menyebabkan pemenuhan kebutuhan pangan di Indonesia berkurang sehingga pemerintah Indonesia masih harus melakukan impor beras dari negeri lain untuk memenuhi kebutuhan pangan di Indonesia [4]. Oleh karena itu, perlu dilakukan prediksi pada luas panen padi di Indonesia agar para petanidapat mengantisipasi kurangnya kebutuhan pangan di Indonesia.

Pada penelitian ini, menggunakan metode *Single Exponential Smoothing*, ARIMA deteksi outlier, dan *Multilayer Perceptron* (MLP) untuk mendapatkan hasil prediksi luas panen padi di Indonesia yang baik dan akurat. Dari tiga metode tersebut akan dicari nilai error MAPE terkecil dan dilakukan prediksi luas panen padi kedepannya. Langkah pertama yaitu memprediksi luas panen padi di Indonesia menggunakan metode *Single Exponential Smoothing*. Kemudian

melakukan perhitungan ARIMA dan mendeteksi *outlier* dari data yang didapat. Selanjutnya, melakukan perhitungan dengan menggunakan metode *Multilayer Perceptron* (MLP), setelah didapat semua nilai MAPE dari masing-masing metode dilakukan perbandingan untuk mencari hasil prediksi luas panen padi yang baik dan akurat.

Pada penelitian sebelumnya yang dilakukan oleh Harun et.al, yang membahas tentang peramalan kedatangan wisatawan mancanegara menggunakan metode *Multilayer Perceptron* (MLP) mendapatkan hasil nilai error yang sangat kecil dan memiliki akurasi yang besar sehingga metode *Multilayer Perceptron* (MLP) dirasa metode yang cukup baik untuk meramalkan kedatangan wisatawan kedepannya [5]. Selain itu, penelitian sebelumnya yang dilakukan oleh Agustinus et.al, yang membahas mengenai penerapan metode *Single Exponential Smoothing* dalam memprediksi suatu penjualan mendapatkan hasil prediksi yang mendekati nilai kenyataan. Hasil tersebut dirasa metode yang cukup baik untuk memprediksi penjualan pada apotik waras wiris [6]. Tujuan dari penelitian ini untuk mengetahui metode prediksi yang baik digunakan untuk melihat perkembangan luas panen padi di Indonesia.

## 2. Tinjauan Pustaka

### 2.1 *Single Exponential Smoothing* (SES)

*Single Exponential Smoothing* adalah salah satu metode yang biasanya digunakan untuk memprediksi jangka pendek kisaran 1 bulan kedepan atau 1 tahun kedepan [7]. Metode ini merupakan salah satu metode time series yang menggunakan data pada masa lampau sebagai pembobotannya untuk melakukan prediksi pada periode yang akan datang [8]. Metode ini dapat diasumsikan datanya naik turun pada nilai mean tetap, tanpa adanya unsur trend atau musiman [6]. Perhitungan *Single Exponential Smoothing* dapat menggunakan rumus sebagai berikut [9] :

$$F_{t+1} = F_t + \alpha(Y_t - F_t) \quad (1)$$

Dimana :

$F_{t+1}$  = Prediksi untuk periode ke  $t + 1$

$F_t$  = Prediksi sebelumnya untuk periode ke  $t$

$\alpha$  = Konstanta perataan ( $0 \leq \alpha \leq 1$ )

$Y_t$  = Permintaan aktual periode sebelumnya

### 2.2 *Autoregressive Integrated Moving Average* (ARIMA)

Model ARIMA termasuk ke dalam teknik pemodelan linear serta berasal dari AR (Autoregressive) differencing dan MA (Moving Average) serta ARMA (Autoregressive Moving Average). Berdasarkan jenis datanya ARIMA dibedakan menjadi dua antara lain ARIMA musiman dan ARIMA non musiman [10]. ARIMA non musiman atau dikenal dengan metode runtun waktu Box-Jenkins yaitu analisis dalam pemodelan ARIMA non musiman hingga tahap prediksi memakai metode dari Box-Jenkins [11]. Model ARIMA sendiri terbagi menjadi 3 tahap dasar yaitu identifikasi, penaksiran serta pengujian. Berikut merupakan tahapan pada metode ARIMA :

#### a) AR (*Autoregressive*)

Model *Autoregressive* dinotasikan dengan  $AR(p)$  atau  $ARIMA(p, 0, 0)$ . Modelnya adalah :

$$Y_t = Y_{t-1}\theta_1 + Y_{t-2}\theta_2 + \dots + Y_{t-p}\theta_p + e_t \quad (6)$$

Dimana :

- $Y_t$  : variabel yang diramalkan  
 $Y_{t-1}, \dots, Y_{t-p}$  : variabel bebas  
 $\theta_1, \dots, \theta_p$  : parameter *autoregressive*  
 $e_t$  : nilai kesalahan

**b) MA (Moving Average)**

Model *moving average* dinotasikan dengan  $MA(q)$  atau  $ARIMA(0,0,q)$ . Modelnya adalah :

$$Y_t = e_t - \phi_1 e_{t-1} - \phi_2 e_{t-2} - \dots - \phi_q e_{t-q} \quad (7)$$

Dimana :

- $Y_t$  : variabel yang diramalkan  
 $\phi_1, \dots, \phi_q$  : parameter *moving average*  
 $e_{t-1}, \dots, e_{t-q}$  : nilai kesalahan pada saat-t  
 $e_t$  : nilai kesalahan

**c) ARMA (Autoregressive Moving Average)**

Merupakan model gabungan dari AR dan MA. Modelnya adalah :

$$Y_t = Y_{t-1}\theta_1 + \dots + Y_{t-p}\theta_p + e_t - \phi_1 e_{t-1} - \dots - \phi_q e_{t-q} \quad (8)$$

Dimana  $Y_{t-1}$  merupakan variabel predictor.

**d) ARIMA**

Runtun waktu dalam proses analisis ARIMA sangat penting, karena data yang digunakan harus stasioner terhadap ragam ataupun terhadap rata-rata, jika data tidak stasioner terhadap keduanya maka harus dilakukannya *diffrencing*[12]. Karena model AR, MA dan ARMA tidak menjabarkan mengenai *defferencing*, maka digunakanlah mode kombinasi yang disebut *Autoregressive Integrated Moving Average* (ARIMA) dan dinotasikan  $ARIMA(p, d, q)$  dengan  $d$  yang menunjukkan *differencing*. Modelnya adalah :

$$\Phi_p(B)D^d Z_t = \mu + \theta_q(B)\alpha_t \quad (9)$$

Dimana,

- $\Phi_p$  : Parameter autoregresif ke-  $p$   
 $B$  : Operator *backshift*  
 $D$  : *Differencing*  
 $p$  : Derajat *autogresif*  
 $d$  : Tingkat proses *differencing*  
 $q$  : Derajat *moving average*

### 2.3 Deteksi Outlier

Deteksi Outlier merupakan suatu nilai pengamatan yang jalannya tidak konsisten pada data *time series*. Outlier mengakibatkan hasil dari analisis data yang didapat tidak valid. Terdapat empat macam jenis outlier yaitu *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift Outlier* (LS), dan *Temporary Change Outlier* (TC) [13].

*Additive Outlier* merupakan kejadian yang memiliki efek pada data *time series* dalam satu periode yaitu pada kurun waktu ke- $t$ . Bentuk umumnya yaitu :

$$Z_t = \begin{cases} X_t, & t = T \\ X_t + \omega, & t \neq T \end{cases}$$

$$Z_t = X_t + \omega I_t^{(T)}$$

$$Z_t = \frac{\theta_{(B)}}{\phi_{(B)}} \alpha_t + \omega I_t^{(T)} \quad (2)$$

*Innovational Outlier* merupakan kejadian yang memiliki efek yang mengikuti jalannya ARMA. Bentuk umumnya yaitu :

$$Z_t = X_t + \frac{\theta_{(B)}}{\phi_{(B)}} \omega I_t^{(T)}$$

$$Z_t = \frac{\theta_{(B)}}{\phi_{(B)}} (\alpha_t + \omega I_t^{(T)}) \quad (3)$$

*Level Shift Outlier* merupakan keadaan yang menguasai deret dalam satu waktu tertentu yang mengakibatkan perubahan secara paten. Bentuk umumnya yaitu :

$$Z_t = X_t + \frac{1}{(1-B)} \omega I_t^{(T)} \quad (4)$$

*Temporary Change Outlier* merupakan keadaan dimana outlier mewujudkan efek pertama sebesar  $\omega$  pada waktu ke- $t$ . Bentuk umumnya yaitu :

$$Z_t = X_t + \frac{1}{(1-\phi B)} \omega I_t^{(T)} \quad (5)$$

Jika  $\delta = 0$  maka *Temporary Change Outlier* menjadi kasus *Additive Outlier*, sedangkan jika  $\delta = 1$  maka *Temporary Change Outlier* akan menjadi kasus *Level Shift Outlier* [14].

#### 2.4 Multilayer Perceptron

*Multilayer Perceptron* atau yang biasa disebut MLP merupakan salah satu model *Neural Network* yang sangat sering digunakan untuk prediksi suatu kejadian. *Multilayer Perceptron* adalah versi asli dari model *Perceptron* yang dikatakan oleh Rosenblatt pada Tahun 1950. *Multilayer Perceptron* mempunyai satu atau lebih lapisan yang tersembunyi dan berada diantara lapisan *input* dan *output*.

Algoritma yang sering digunakan untuk membentuk *Multilayer Perceptron* yaitu *Backpropagation*. *Backpropagation* adalah bagian dari kecerdasan buatan yang dilakukan dengan dua tahap yaitu *forward pass* serta *backward pass*. *Forward pass* digunakan untuk menghitung galat yang ada pada target dan prediksi. Sedangkan *backward pass* digunakan untuk menghitung balik galat sebagai pembetulan bobot sinaptik pada neuron yang ada [17].

#### 2.5 Mean Absolute Percentage Error (MAPE)

Metode yang biasa digunakan dalam mengetahui besar *error* dalam suatu system adalah MAPE. Metode evaluasi ini digunakan karena variabel peramalan menentukan besarnya

kesalahan peramalan dibandingkan dengan nilai asli [15]. Perhitungan MAPE dilakukan menggunakan rata-rata presentase absolute kesalahan dan biasa digunakan untuk data dengan interval kurun waktu berbeda [16]. Nilai MAPE dapat dihitung menggunakan rumus persamaan (10).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \tag{10}$$

Dimana :

$Y_t$  = Data asli

$\hat{Y}_t$  = Data hasil prediksi

$n$  = Banyaknya data

**Tabel 1:**Penjelasan Nilai MAPE

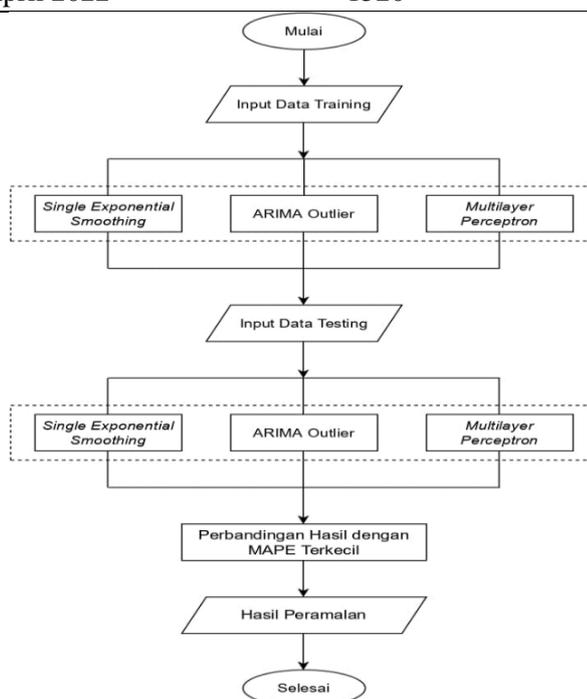
MAPE	< 10%	10% - 20%	20% - 50%	> 50%
------	-------	-----------	-----------	-------

### 3. Metodologi Penelitian

Data yang digunakan pada penelitian kali ini adalah data luas panen padi di Indonesia dari bulan Januari 2018 hingga April 2022. Data tersebut berupa angka sehingga jenis data termasuk dalam data kuantitatif. Data Penelitian sebagaimana pada Tabel 2 dan Metode tersebut dipresentasikan dalam diagram alir pada **Gambar 1**

**Tabel 2:**Sampel Data Luas Panen Padi di Indonesia

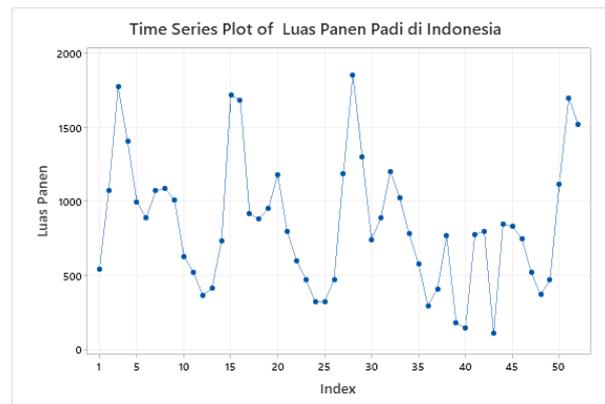
Periode	Luas Panen Padi (Ha)
Januari 2018	542
Februari 2018	1075
⋮	⋮
Maret 2022	1700
April 2022	1520



**Gambar 1.** Diagram Alir Proses Peramalan Luas Panen Padi di Indonesia

#### 4. Hasil dan Pembahasan

Langkah yang harus dilakukan pertama kali ialah melakukan plotting data luas panen padi di Indonesia pada bulan Januari 2018 sampai April 2022. Dilakukannya plotting data tersebut adalah agar dapat terlihat pola data *time series* yang terbentuk. Pola suatu data berguna untuk mengidentifikasi metode yang cocok digunakan dalam melakukan peramalan. Plotting data luas panen padi pada Gambar 2.



**Gambar 2** : Plot Pola Time Series Luas Panen Padi di Indonesia

Gambar 2 terlihat bahwa pola time series menunjukkan pola nonstasioner jadi tidak terindikasi adanya pola musiman, untuk pola tren juga tidak terjadi pada data luas panen padi. Setelah dilakukannya analisis pola *time series*, selanjutnya adalah dilakukan pembagian data *training* dan *testing*. Pembagian data dilakukan 80% data *training* dan 20% data *testing*. Sehingga berdasarkan total 52 data didapatkan 42 data *training* dan 10 data *testing*. Kemudian dilakukan pembentukan model untuk menentukan metode terbaik dalam melakukan peramalan luas panen padi di Indonesia untuk tahun berikutnya.

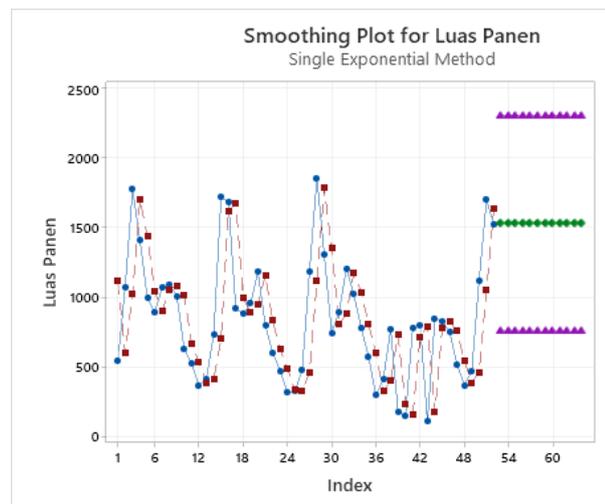
##### 4.1 Single Exponential Smoothing

Metode *single exponential smoothing* digunakan karena pola time series data didapat adalah nonstationer. Model *single exponential smoothing* menggunakan satu parameter untuk membentuk parameternya, parameter yang digunakan biasanya adalah  $\alpha$  ( $\alpha$ ). Rentang yang digunakan adalah 0.5 – 0.9 untuk nilai parameternya. Kemudian dilakukan *trial and error* pada rentang parameter tersebut untuk dicari nilai error terkecilnya. Selanjutnya, hasil MAPE pada setiap parameter pada **Tabel 3**.

**Tabel 3**: Parameter SES dan nilai MAPE

Ke-	Alpha	MAPE %
1	0.5	57
2	0.6	56
3	0.7	55
4	0.8	54
5	0.9	53

Berdasarkan **Tabel 3**, telah dibentuk enam model menggunakan nilai  $\alpha$  yang berbeda. Berdasarkan model yang didapat terlihat perbedaan nilai mape yang sangat kecil antara parameter – parameter data saat dilakukan *trial and error*. Dari percobaan tersebut dapat terlihat bahwa pada parameter  $\alpha$  0.9 memiliki nilai MAPE yang paling kecil, yakni 53%. Selanjutnya adalah melakukan plotting dengan menggunakan model terbaik yang telah didapatkan. Plotting hasil peramalan menggunakan SES pada **Gambar 3**.

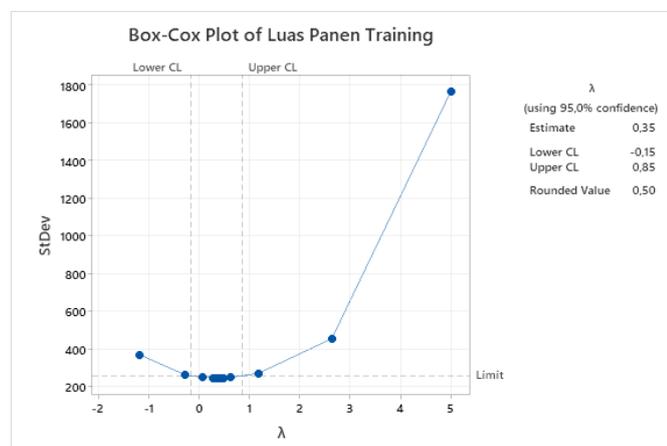


**Gambar 3:** Plot hasil Peramalan menggunakan SES ( $\alpha$  0.9)

Berdasarkan **Gambar 3** dapat dilihat bahwa hasil prediksi menunjukkan pola yang datar, kemudian nilai mape yang didapatkan adalah 53% yang didasarkan pada **Tabel 1**. Kategori nilai error tersebut kurang baik dalam melakukan peramalan.

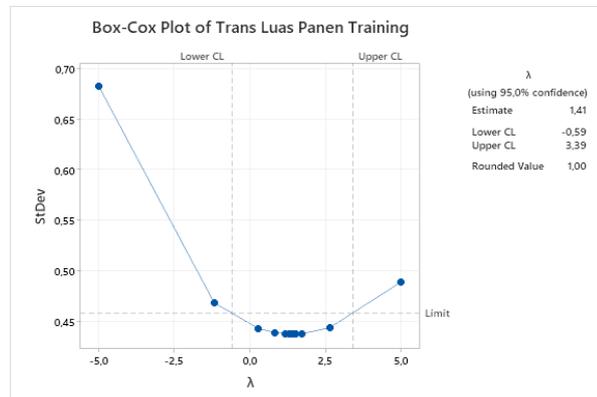
#### 4.2 ARIMA Outlier

Plot data luas panen padi di Indonesia pada **Gambar 2**, menunjukkan secara visual data nonstasioner. Data akan stasioner jika nilai pada data berada pada garis rata-rata dan konstan terhadap waktu. Data yang tidak stasioner harus distasionerkan dalam *varians* dan dalam *means*. Stasioner dalam *varians* digunakan *Bo-Cox test*. Nilai *rounded value* sama dengan 1 maka data dikatakan sudah stasioner.



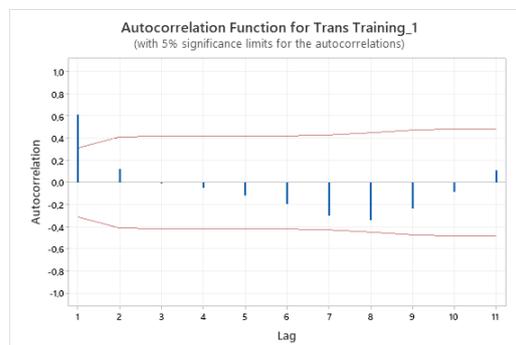
**Gambar 5** : Box-Cox data luas panen padi di Indonesia

Pada **Gambar 5**, nilai *rounded value* belum bernilai 1 maka data perlu ditransformasikan. *Box-Cox* Hasil transformasi pada **Gambar 6**.

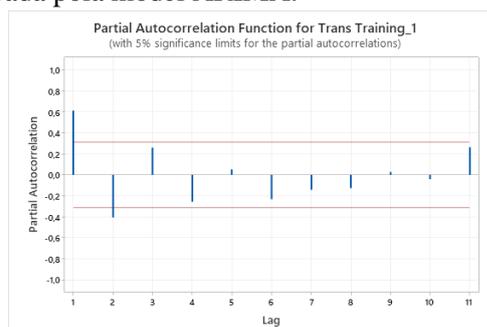
**Gambar 6** : *Box-Cox* hasil transformasi data Persediaan bahan baku

Pada **Gambar 6**. Terlihat bahwa telah dilakukan transformasi dan didapatkan nilai *rounded value* sama dengan satu, maka data luas panen padi di Indonesia sudah Stasioner.

Selanjutnya dilakukan uji data terhadap stasioneritas pada *means* atau tidak. Acuan dalam melihat stasioner dalam mean dapat dilakukan dengan plot ACF (*Autocorrelation Function*). *Lag* pada plot ACF menunjukkan nilai moving autokorelasi pada data.

**Gambar 7** : Plot ACF data Luas Panen Padi di Indonesia

**Gambar 7**. menunjukkan bahwa data tersebut stasioner dalam *means* karena lag pertama sudah memenuhi atau keluar batas maka model tersebut adanya indikasi MA 1. Kemudian dilakukan plot PACF atau (*Partial Autocorrelation Function*). *Lag* pada plot PACF mengindikasikan nilai MA pada pola model ARIMA.



**Gambar 8** : Plot PACF data Luas Panen Padi di Indonesia

**Gambar 8.** menunjukkan bahwa data tersebut stasioner dalam *means* karena lag pertama dan lag kedua sudah memenuhi atau keluar batas maka model tersebut adanya indikasi AR 1 dan AR 2. Sehingga plot pada **Gambar 8** dapat digunakan dalam menentukan model ARIMA yang sesuai dalam melakukan peramalan. Model yang baik merupakan model yang estimasi parameternya memiliki nilai *p-value* yang signifikan ( $< 0,05$ ) dan juga memenuhi uji *white noise*, distribusi normal, dan memiliki nilai MS yang kecil. Dugaan model ARIMA yang terbentuk dapat dilihat pada **Tabel 4**.

**Tabel 4.** Dugaan Model ARIMA

Model	Estimasi Parameter				Pengujian		MS
	Parameter	Coef	SE Coef	P-Value	<i>White noise</i>	<i>normality</i>	
ARIMA(0,0,1)	AR(1)	-0,964	0,0827	0,000	0,234	$> 0,150$	0,235
ARIMA(1,0,0)	MA(1)	0,618	0,124	0,000	0,123	$> 0,150$	0,342
ARIMA(2,0,0)	AR(1)	0,897	0,143	0,000	0,380	$> 0,150$	0,282
	AR(2)	-0,443	0,143	0,004			
ARIMA(1,0,1)	AR(1)	0,231	0,162	0,161	0,648	$> 0,150$	0,229
	MA(1)	-0,9547	0,0782	0,000			
ARIMA (2,0,1)	AR(1)	1,603	0,115	0,000	0,266	$> 0,150$	0,285
	AR(2)	-0,8	0,12	0,000			
	MA(1)	0,9481	0,0894	0,000			

**Tabel 4** adalah model terbaik atau pada model ARIMA(1,0,1). Hal tersebut dikarenakan estimasi parameternya menunjukkan *p-value* yang signifikan serta memenuhi pengujian *white noise* dengan nilai  $0,196 > 0,05$  dan uji distribusi normal yang bernilai  $> 0,150$  serta nilai MS yang paling kecil diantara model lain yang nilai parameter dan uji lainnya juga memenuhi. Berdasarkan model terbaik ARIMA tersebut, jika dilakukan forecasting akan menghasilkan hasil peramalan yang tidak memenuhi pola sata sebelumnya. Oleh karena itu, harus dilakukannya outlier pada model arima terbaik.

Langkah selanjutnya ialah dilakukan deteksi outlier yang ada dengan menggunakan model ARIMA (1,0,1). Sehingga didapatkan tiga outlier seperti pada **Tabel 5**.

**Tabel 5.** Identifikasi Outlier pada model ARIMA (1,0,1)

<i>Obs</i>	<i>Type</i>	<i>Estimate</i>	<i>Square</i>	<i>Chi-Square</i>
35	Shift	-412,48	10,70	0,0011
3	Additive	367,93	8,21	0,0042
28	Additive	161,84	4,23	0,0398

**Tabel 5** merupakan hasil dari identifikasi outlier pada ARIMA (1,0,1) terdapat tiga Obs dengan dua jenis tipe data sehingga terdapat data *additive outlier* (AO35), *level shift* (LS3), dan

*level shift (LS28)*. Kemudian tahap selanjutnya adalah dilakukan estimasi model ARIMA (1,0,1) dengan menambahkan outlier yang telah terbentuk harus memenuhi signifikansi berdistribusi normal dan *white-noise*. Berikut merupakan uji estimasi signifikansi parameter model pada **Tabel 6**.

**Tabel 6.** Identifikasi Outlier pada model ARIMA (1,0,1)

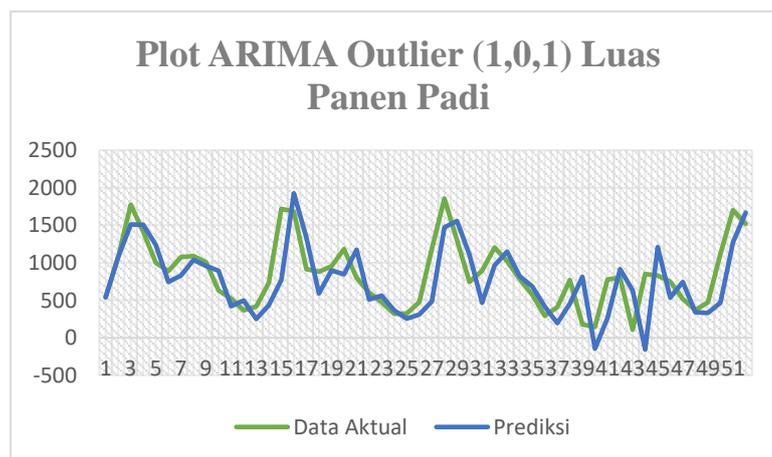
Parameter	Estimate	p-value	Lag	Variabel	Keputusan
MA1	-0,716	< 0,0001	1	z	Signifikan
AR1	0,812	< 0,0001	1	z	Signifikan

**Tabel 6** memiliki taraf signifikan *p-value* kurang dari 0.05 maka dapat dikatakan parameter telah signifikan dengan model outlier yang ada dan dapat dimasukkan pada model ARIMA. Selanjutnya uji *White-Noise* pada **Tabel 7**.

**Tabel 7.** Identifikasi Outlier pada model ARIMA (1,0,1)

Lag	Chi-Sqrt	DF	P-value	Keputusan
6	2,63	4	0,6223	<i>White-Noise</i>
12	8,84	10	0,5474	
18	2,97	16	0,0544	
24	29,99	22	0,1188	

**Tabel 7** sudah memenuhi syarat *white-noise*, maka selanjutnya dilakukan plot hasil dari model yang didapat seperti pada **gambar 9**.



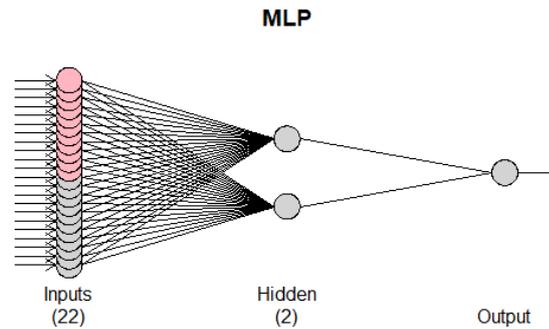
**Gambar 9 :** Plot ARIMA Outlier (1,0,1) Luas Panen Padi di Indonesia

Selanjutnya dilakukan uji nilai error dengan MAPE, untuk nilai error yang didapatkan dari MAPE adalah 2,19%. Hal ini dikatakan model yang dibentuk sangat baik karena <10%,

sehingga model ARIMA Outlier (1,0,1) dapat digunakan untuk prediksi luas panen padi di Indonesia.

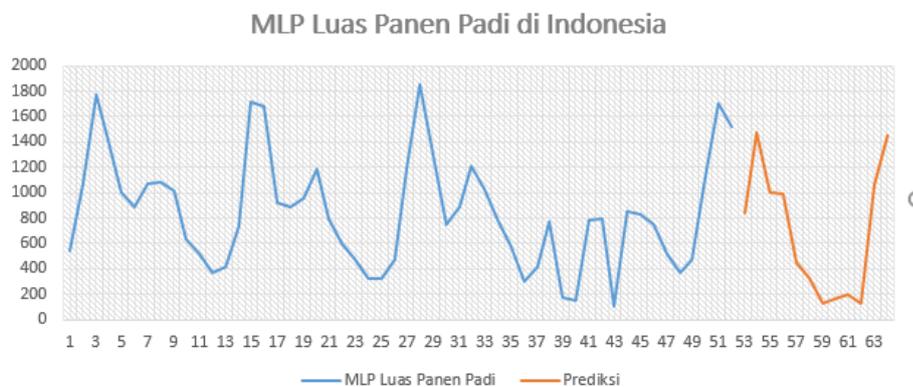
### 4.3 Multilayer Perceptron

Dengan menggunakan *data training* dan *testing* yang telah dibagi maka diperoleh fungsi *Multilayer Perceptron* (MLP) dengan arsitektur yang optimal yaitu 22 neuron input, 2 neuron tersembunyi, dan 1 neuron output. Ilustrasi layer pada MLP diperlihatkan pada **Gambar 11**.



**Gambar 11:** Arsitektur Multilayer Perceptron

Dari layer yang telah ditentukan, didapatkan nilai peramalan untuk periode ke depan. Hasil prediksi untuk 12 bulan ke depan menggunakan MLP diperlihatkan pada **Gambar 12**.



**Gambar 12:** Hasil Prediksi menggunakan Multilayer Perceptron

Dari **Gambar 12** menunjukkan kecenderungan pola data yang sejenis dengan data aktual yang memiliki pola kenaikan pada bulan – bulan tertentu. Maka pada data asli yang telah dimiliki luas panen padi di Indonesia telah sesuai dengan model MLP yang telah dibentuk. Dari hasil peramalan tersebut didapatkan nilai MAPE yang sangat kecil yaitu sebesar 0.89%.

#### 4.4 Perbandingan Hasil

Metode terbaik merupakan metode yang memiliki nilai kesalahan peramalan minimum. Nilai kesalahan tersebut dapat dilihat dari nilai MAPE yang telah didapatkan. Perbandingan nilai MAPE dari metode SES, ARIMA Outlier dan MLP pada **Tabel 8**.

**Tabel 8 :** Tabel Perbandingan nilai MAPE

Model	MAPE %
Single Exponential Smoothing	53
Arima Outlier	2,19
Multilayer Perceptron	0,89

Dari **Tabel 8** dapat dilihat ketiga metode mempunyai keakurasian yang baik dalam melakukan peramalan. Hal tersebut sesuai dengan yang ditunjukkan pada **Tabel 1** bahwa apabila nilai MAPE pada kisaran  $<10\%$  maka model yang dihasilkan sangat baik. Namun, dari ketiga metode tersebut dari nilai MAPE yang didapat metode *Multilayer Perceptron* lebih kecil daripada metode lainnya sehingga lebih akurat dalam meramalkan luas panen padi di Indonesia.

#### 5. Kesimpulan

Berdasarkan hasil penelitian saat dilakukan perbandingan antara tiga metode yaitu SES, ARIMA Outlier, dan *Multilayer Perceptron* diperoleh nilai MAPE yang paling kecil yaitu dengan menggunakan metode *Multilayer Perceptron* dengan nilai MAPE sebesar 0,89%. Hasil peramalan menunjukkan bahwa luas panen padi di Indonesia pada dua belas bulan mendatang akan memiliki pola yang hamper mirip dengan data aktual sebelumnya.

#### Referensi :

- [1] P. S. Patti, E. Kaya, and C. Silahooy, "Analisis Status Nitrogen Tanah Dalam Kaitannya Dengan Serapan N Oleh Tanaman Padi Sawah Di Desa Waimital, Kecamatan Kairatu, Kabupaten Seram Bagian Barat," *Agrologia*, vol. 2, no. 1, pp. 51–58, 2018, doi: 10.30598/a.v2i1.278.
- [2] E. I. Zulfa, D. A. Ferryan, and D. C. R. Novitasari, "Analisis Pendekatan Statistik Dan Fuzzy Mamdani Dalam Prediksi Produktivitas Padi," *Maj. Ilm. Mat. dan Stat.*, vol. 22, no. 1, p. 105, 2022, doi: 10.19184/mims.v22i1.30304.
- [3] I. I. Sari and E. F. Kurniawati, "Peramalan Produksi Padi Menggunakan Metode Least Square Di Desa Leranwetan Kecamatan Palang Kabupaten Tuban," *J. Unirow (Math Vision)*, vol. 02, no. 01, pp. 23–28, 2020.
- [4] Maswadi, "Analisis Hubungan Antara Luas Panen Produksi Tenaga Kerja Pertanian Terhadap Pdrb Di Kota Pontianak," *J. Soc. Econ. Agric.*, vol. 6, no. 2, pp. 9–15, 2017.
- [5] H. Mukhtar, R. Muhammad, T. Reny Medikawati, and Yoze Rizki, "Peramalan Kedatangan Wisatawan Mancanegara Ke Indonesia Menurut Kebangsaan Perbulannya Menggunakan Metode Multilayer Perceptron," *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 2, no. 2, pp. 113–119, 2021, doi: 10.37859/coscitech.v2i2.3324.
- [6] A. B. Santoso, M. S. Rumatna, and K. Isnaningtyas, "Penerapan Metode Single Exponential Smoothing Untuk Analisa Peramalan Penjualan," *J. Media Inform. Budidarma*, vol. 5, no. 2, p. 756, 2021, doi: 10.30865/mib.v5i2.2951.

- [7] D. M. Efendi and F. Ardhy, "Penerapan Data Mining Untuk Peramalan Penjualan Obat dengan Menggunakan Single Exponential Smoothing di Apotek Hamzah Farma," *Semin. Nas. Teknol. dan Bisnis*, pp. 198–203, 2018.
- [8] S. Alfari, "Sistem Prediksi Menggunakan Metode Single Exponential Smoothing," *J. Appl. Bus. Econ.*, vol. 4, no. 1, pp. 80–95, 2017.
- [9] N. L. W. S. R. Ginantra and I. B. G. Anandita, "Penerapan Metode Single Exponential Smoothing Dalam Peramalan Penjualan Barang," *Sains Komput. dan Inform.*, vol. 3, no. September, pp. 433–441, 2019.
- [10] D. Rakhmawati, E. Tripustikasari, and E. Model, "Estimasi Model Arima Non Musiman Untuk Memprediksi Data Minyak Dunia," *Konf. Nas. Sist. Inf.*, pp. 8–9, 2018.
- [11] N. Salwa, N. Tatsara, R. Amalia, and A. F. Zohra, "Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average)," *J. Data Anal.*, vol. 1, no. 1, pp. 21–31, 2018, doi: 10.24815/jda.v1i1.11874.
- [12] T. Yunita, "Peramalan Jumlah Penggunaan Kuota Internet Menggunakan Metode Autoregressive Integrated Moving Average ( ARIMA )," *J. Math. Theory Appl.*, vol. 1, no. 2, pp. 16–22, 2019.
- [13] A. M. Huda, A. Choiruddin, O. Budiarto, and Sutikno, "Peramalan Data Curah Hujan Dengan Seasonal Autoregressive Integrated Moving Average (Sarima) Dengan Deteksi Outlier Sebagai Upaya Optimalisasi Produksi Pertanian Di Kabupaten Mojokerto," *Semin. Nas. Kedaulatan Pangan dan Energi*, 2012.
- [14] A. F. Sa'adah, D. Ispriyanti, and Suparti, "Prediksi Tinggi Pasang Air Laut di Kota Semarang dengan Menggunakan Moving Autoregressive Integrated Moving Average (SARIMA) dan Deteksi Outlier," *J. GAUSSIAN*, vol. 3, no. 23, pp. 273–282, 2019, doi: 10.15797/concom.2019..23.009.
- [15] Elen Riswana Safila Putri, Fahriza Novianti, Yasirah Rezqita Aisyah Yasmin, and Dian Candra Rini Novitasari, "Prediksi Kasus Aktif Kumulatif Covid-19 Di Indonesia Menggunakan Model Regresi Linier Berganda," *Transform. J. Pendidik. Mat. dan Mat.*, vol. 5, no. 2, pp. 567–577, 2021, doi: 10.36526/tr.v5i2.1231.
- [16] A. Krisma, M. Azhari, and P. P. Widagdo, "Perbandingan Metode Double Exponential Smoothing Dan Triple Exponential Smoothing Dalam Parameter Tingkat Error Mean Absolute Percentage Error ( MAPE ) dan Means Absolute Deviation ( MAD )," *Pros. Semin. Nas. Ilmu Komput. dan Teknol. Inf.*, vol. 4, no. 2, pp. 81–87, 2019.
- [17] P. Githa Pratiwi, I. Ketut Gede Darma Putra, and D. Purnami Singgih Putri, "Peramalan Jumlah Tersangka Penyalahgunaan Narkoba Menggunakan Metode Multilayer Perceptron," *J. Ilm. Merpati (Menara Penelit. Akad. Teknol. Informasi)*, vol. 7, no. 2, p. 143, 2019, doi: 10.24843/jim.2019.v07.i02.p06.