

Perbandingan Metode *Seasonal* ARIMA dan *Extreme Learning Machine* dalam Prediksi Produksi Padi di Sulawesi Selatan

Rini Jamal^{1*}, Andi M Alfin Baso², Andi Febriyanti³, Sitti Sahriman⁴, Siswanto⁵,
Andi Isna Yunita⁶, A. Muthiah Nur Angriany⁷, A Rahmiati Rahim⁸,
Muhammad Fadil⁹

¹²³⁴⁵⁶⁷⁹Departemen Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Hadanuddin, Makassar, 60294, Indonesia

⁸BPS Provinsi Sulawesi Selatan, Makassar, 90125, Indonesia

* Corresponding author, email: rinijamall111@gmail.com

Abstract

South Sulawesi is one of the provinces that significantly contributes to national rice production. Therefore, accurate forecasting of rice production is crucial for food security planning and agricultural policy-making. This study aims to compare the performance of the Seasonal Autoregressive Integrated Moving Average (SARIMA) and Extreme Learning Machine (ELM) methods in predicting rice production in South Sulawesi. SARIMA is a statistical forecasting method effective for data with seasonal patterns, while ELM is a machine learning approach capable of handling complex relationships among variables with high computational speed. Rice production data from the Central Statistics Agency (Badan Pusat Statistik) were used to evaluate the accuracy of both methods. The evaluation was conducted using forecasting error metrics such as Mean Absolute Percentage Error (MAPE). The results show that the SARIMA(1,1,0)(1,1,0)¹² model outperformed ELM in predicting rice production in South Sulawesi. This is indicated by a lower MAPE value of 19.937%, compared to 21.632% for the ELM method.

Keywords: Rice Production, SARIMA, Extreme Learning Machine, Forecasting, MAPE.

Abstrak

Sulawesi Selatan merupakan salah satu provinsi dengan kontribusi besar dalam produksi beras nasional. Oleh karena itu, prediksi produksi padi yang akurat sangat penting dalam perencanaan ketahanan pangan dan pengambilan kebijakan pertanian. Penelitian ini bertujuan untuk membandingkan performa metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan *Extreme Learning Machine* (ELM) dalam memprediksi produksi padi di Sulawesi Selatan. SARIMA merupakan metode peramalan berbasis statistik yang efektif untuk data dengan pola musiman, sedangkan ELM adalah metode pembelajaran mesin yang mampu menangani hubungan kompleks antar variabel dengan kecepatan komputasi tinggi. Data produksi padi dari Badan Pusat Statistik digunakan untuk menguji akurasi kedua metode. Evaluasi dilakukan menggunakan ukuran kesalahan peramalan seperti *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa metode SARIMA(1,1,0)(1,1,0)¹² memiliki performa lebih baik dibandingkan ELM dalam memprediksi produksi padi di Sulawesi Selatan. Hal ini ditunjukkan oleh nilai MAPE peramalan yang lebih rendah, yaitu 19.937%, sementara metode ELM memiliki nilai MAPE sebesar 21.632%.

Kata Kunci: Produksi Padi, SARIMA, *Extreme Learning Machine*, Forecasting, MAPE.

1. Pendahuluan

Indonesia memiliki sejumlah wilayah dengan potensi produksi beras yang tinggi, salah satunya adalah Sulawesi Selatan. Berdasarkan data Badan Pusat Statistik, Sulawesi Selatan menempati peringkat keempat sebagai provinsi penghasil beras terbesar di Indonesia pada tahun 2024, dengan total produksi mencapai 4.82 juta ton [1]. Sulawesi Selatan merupakan daerah penghasil beras utama di luar Pulau Jawa, provinsi ini didukung oleh sistem irigasi yang baik serta petani yang terus berupaya meningkatkan hasil panen. Namun, produksi padi dapat mengalami fluktuasi akibat faktor cuaca, perubahan iklim, serta kebijakan pertanian [2], sehingga diperlukan sistem prediksi yang akurat untuk mengantisipasi perubahan produksi di masa mendatang.

Prediksi produksi padi menjadi aspek penting dalam perencanaan ketahanan pangan dan pengambilan kebijakan di sektor pertanian. Dengan adanya prediksi yang akurat, pemerintah dan pemangku kepentingan dapat mengantisipasi fluktuasi produksi, mengoptimalkan distribusi, serta menghindari ketimpangan antara ketersediaan dan kebutuhan pangan. Terdapat beberapa metode yang dapat digunakan dalam memprediksi produksi padi, antara lain metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan metode *Extreme Learning Machine* (ELM) [3].

SARIMA merupakan salah satu metode peramalan yang efektif untuk data deret waktu dengan pola musiman, seperti produksi padi yang cenderung berfluktuasi. Model ini merupakan pengembangan dari ARIMA yang menggabungkan aspek *Autoregressive* (AR) dan *Moving Average* (MA) serta mampu menangani data dengan komponen musiman maupun non-musiman [4]. Dengan tambahan parameter musiman, SARIMA memungkinkan analisis dan peramalan deret waktu yang menunjukkan pola musiman secara lebih akurat. Kusuma dkk. (2024) dalam penelitiannya tentang prediksi produksi beras di Nusa Tenggara Barat menunjukkan bahwa metode ini memiliki tingkat akurasi tinggi dalam meramalkan produksi pada puncak musim panen [5].

Selain metode statistik seperti SARIMA, pendekatan berbasis kecerdasan buatan juga semakin banyak diterapkan dalam bidang prediksi, salah satunya adalah metode ELM. Metode ini merupakan pengembangan dari jaringan saraf tiruan (*Artificial Neural Network*) yang memiliki keunggulan dalam kecepatan komputasi dan kemampuan generalisasi yang baik. ELM dapat menangani kompleksitas hubungan antara variabel *input* dan *output* dengan lebih fleksibel dibandingkan metode konvensional [6].

Penelitian ini bertujuan untuk membandingkan performa metode SARIMA dan ELM dalam memprediksi produksi padi di Sulawesi Selatan. Dengan menganalisis akurasi kedua metode, diharapkan dapat diperoleh model prediksi yang lebih andal dalam mendukung pengambilan keputusan di sektor pertanian. Hasil penelitian ini diharapkan memberikan kontribusi bagi pengembangan strategi pertanian berbasis data dan meningkatkan efisiensi produksi padi di Indonesia.

2. Material dan Metode

2.1 Seasonal Autoregressive Integrated Moving Average (SARIMA)

SARIMA merupakan model deret waktu yang digunakan untuk data dengan interval tetap serta menunjukkan pola musiman, seperti bulanan, triwulanan, semesteran, atau tahunan [7]. SARIMA sendiri dikembangkan dari metode peramalan *Autoregressive Integrated Moving Average* (ARIMA). Notasi umum dari SARIMA adalah $(p, d, q)(P, D, Q)^S$ di mana p, d, q merupakan model komponen nonmusiman dan P, D, Q merupakan model komponen musiman, serta S merupakan jumlah dari periode musiman. Elemen-elemen utama dalam SARIMA berasal dari model ARIMA (p, d, q) , yang terdiri dari tiga komponen utama, yaitu [8].

a) *Autoregressive* (AR atau p)

Parameter p menunjukkan jumlah lag yang dimasukkan dalam model.

b) *Integrated* (I atau d)

Parameter d menunjukkan tingkat diferensiasi yang diterapkan. Ini menggambarkan seberapa banyak langkah diferensiasi yang diperlukan agar deret waktu menjadi stasioner.

c) *Moving Average* (MA atau q)

Nilai q menunjukkan jumlah lag yang akan digunakan dalam model.

Persamaan umum dari SARIMA dapat dilihat pada persamaan (1).

$$\phi_p(B)\phi_P(B^S)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\theta_Q(B^S)a_t \quad (1)$$

dengan:

Z_t : Pengamatan pada waktu- t

$\phi_p(B)$: *Autoregressive* non-musiman

$\phi_P(B^S)$: *Autoregressive* musiman

a_t : Residual pada waktu ke- t

$(1-B)^d$: *Differencing* non-musiman

$(1-B^S)^D$: *Differencing* musiman

$\theta_q(B)$: *Moving Average* non-musiman

$\theta_Q(B^S)$: *Moving Average* musiman

Langkah-langkah umum dalam pemodelan SARIMA adalah sebagai berikut [9]:

1. Identifikasi model

Data deret waktu yang akan diprediksi harus bersifat stasioner dalam *mean* dan *varians*. Jika data belum stasioner, perlu dilakukan transformasi terlebih dahulu. Selanjutnya, model tentatif ditentukan berdasarkan pola pada plot ACF dan PACF. Pemilihan model SARIMA dapat dilakukan dengan menggunakan nilai *Akaike Information Criterion* (AIC).

2. Pendugaan parameter

Langkah ini dilakukan untuk mengevaluasi signifikansi parameter dalam model tentatif yang telah dipilih.

3. Diagnostik model

Diagnostik model dilakukan untuk menilai kelayakan model yang telah dipilih, memastikan bahwa sisaan berdistribusi normal, dan tidak menunjukkan autokorelasi.

4. Peramalaan

Peramalan adalah proses memprediksi kejadian di masa depan dengan menganalisis data historis dan mengaplikasikannya ke masa mendatang menggunakan suatu model matematis.

2.2 Extreme Learning Machine (ELM)

ELM merupakan metode pembelajaran mesin yang dikenal karena efisiensinya dalam mengolah data dengan cepat dan sederhana. ELM merupakan pendekatan baru dalam jaringan saraf tiruan, yang menyerupai cara kerja otak manusia, di mana terdapat sejumlah neuron yang saling terhubung. Neuron-neuron ini mentransmisikan informasi dari satu ke yang lainnya, dengan setiap informasi disimpan dalam bobot tertentu [10]. Persamaan (2) berikut adalah model runtun waktu ELM yang memiliki m unit pada satu *hidden layer*:

$$\hat{x}_t = \sum_{i=1}^m \beta_i g(w_i \cdot x_j + b_i) \quad (2)$$

dengan:

$\hat{x}_t$: data prediksi


β_i : bobot yang menghubungkan *neuron hidden* dengan *neuron output*

w_i : bobot yang menghubungkan *neuron input* dengan *neuron hidden*

x_j : vektor data input

b_i : bobot bias ke neuron hidden

Secara umum struktur jaringan ELM ditunjukkan pada Gambar 1 berikut:



Gambar 1. Arsitektur Jaringan *Extreme Learning Machine*

2.2.1. Algoritma ELM

Secara umum algoritma ELM terdiri dari tiga tahap utama [11]:

- a. Inisialisasi secara acak bobot dan bias antara lapisan masukan dan lapisan tersembunyi.
- b. Untuk masing-masing data hitung keluaran pada lapisan tersembunyi dengan persamaan (3):

$$Z_{net_i} = b_i + \sum_{j=1}^N x_{kj} \cdot w_{ji} \quad (3)$$

dengan:

Z_{net_i} : Keluaran lapisan tersembunyi yang belum diaktivasi

b_i : bias antara lapisan masukan menuju lapisan tersembunyi

x_{kj} : nilai masukan pada lapisan masukan

w_{ji} : bobot antara lapisan masukan menuju lapisan tersembunyi

- c. Hitung bobot pada lapisan keluaran (β) menggunakan aturan *Moore-Penrose inverse* matriks pada persamaan (4).

$$\beta = H^*T \quad (4)$$

dengan:

β : Bobot pada lapisan keluaran

H : Matriks pseudo-inverse Moore-Penrose, yaitu: $H^* = H^T(HH^T)^{-1}$

T : Matriks target data

Hitung keluaran akhir pelatihan (y) menggunakan persamaan (5):

$$y_k = \sum_{i=1}^N \beta_i \cdot g(x_{kj} \cdot w_{ij} + b_i) \quad (5)$$

dengan:

y_k : Keluaran ELM

β : Bobot lapisan keluaran

$g(x)$: Fungsi aktivasi keluaran pada lapisan tersembunyi

2.2.2. Normalisasi Data

Normalisasi data merupakan proses transformasi pada suatu kumpulan data yang memiliki rentang nilai tidak seimbang. Salah satu teknik normalisasi adalah *Min-Max Normalization*, yang ditunjukkan dalam Persamaan 6 berikut [12].

$$d' = \frac{d - \min(p)}{\max(p) - \min(p)} \quad (6)$$

dengan:

d' : data normalisasi

d : data sebenarnya

$\min(p)$: nilai minimal fitur p

$\max(p)$: nilai maksimal fitur p

2.3. Uji Validitas

Uji validitas digunakan untuk menilai ketepatan hasil peramalan dengan menganalisis ukuran kesalahan peramalan. Salah satu metode yang dapat digunakan dalam mengevaluasi akurasi model peramalan adalah dengan menghitung nilai *Mean Absolute Percentage Error* (MAPE). MAPE dihitung dengan membagi kesalahan absolut setiap periode dengan nilai observasi aktual pada periode tersebut. MAPE dapat ditentukan menggunakan persamaan (7) berikut [13].

$$MAPE = \left(\frac{100\%}{n} \right) \sum_{t=1}^n \frac{|X_t - F_t|}{X_t} \quad (7)$$

dengan:

X_t : Data aktual pada periode t

F_t : Nilai prediksi pada periode t

Sebuah model dikatakan memiliki kinerja yang sangat baik apabila nilai MAPE kurang dari 10%. Jika MAPE berada dalam rentang 10% hingga 20%, maka model tersebut masih dianggap memiliki kinerja yang baik [11].

2.4. Sumber Data

Data yang digunakan dalam penelitian ini adalah data bulanan produksi padi di Provinsi Sulawesi Selatan (dalam ton GKG). Data tersebut diperoleh dari *website* Badan Pusat Statistik (BPS). Penelitian ini menggunakan data produksi padi dari tahun 2018 hingga 2024.

2.5. Metode Analisis


Langkah-langkah dalam penelitian ini meliputi:

1. Mengumpulkan data produksi padi dari Januari 2018 hingga Desember 2024.
2. Melakukan analisis Deskriptif
3. Melakukan pengolahan data dengan Metode *Seasonal* ARIMA
 - a. Uji Kestasioneran Data
 - b. Identifikasi Model Sementara
 - c. Uji Asumsi Residual
 - d. Hasil *Forecasting* Model SARIMA
4. Melakukan pengolahan data dengan Metode *Extreme Learning Machine*
 - a. Normalisasi Data
 - b. Proses *Training*
 - c. Hasil *Forecasting* Model ELM
5. Uji Validitas dan Perbandingan Metode
6. Menginterpretasikan hasil model.

3. Hasil dan Diskusi

3.1 Analisis Deskriptif

Berdasarkan data BPS, produksi padi di Sulawesi Selatan seperti pada Gambar 2, menunjukkan tren fluktuatif dalam beberapa tahun terakhir. Produksi tertinggi tercatat pada tahun 2018 sebesar 5.75 juta ton GKG, namun mengalami penurunan tajam hingga mencapai titik terendah pada tahun 2020 sebesar 4.69 juta ton. Setelah itu, produksi kembali meningkat dan mencapai 5.36 juta ton pada 2022 sebelum mengalami penurunan lagi pada 2023 dan 2024 dengan angka masing-masing 4.94 juta ton dan 4.82 juta ton. Hal ini menunjukkan adanya dinamika produksi yang dipengaruhi oleh berbagai faktor, seperti kondisi cuaca, kebijakan pertanian, dan produktivitas lahan.



Gambar 2. Plot Data *Time Series* Produksi Padi Januari 2018-Desember 2024


Sebagaimana ditunjukkan pada Gambar 2, produksi padi di Sulawesi Selatan mengalami pola musiman yang berulang setiap tahunnya. Pola ini ditandai dengan adanya fluktuasi yang konsisten, di mana produksi mencapai puncaknya pada bulan April-Mei dan Agustus-Oktober, sementara penurunan produksi terjadi pada Juni-Juli dan November-Maret. Peningkatan produksi umumnya bertepatan dengan musim panen utama, sedangkan penurunan produksi dapat dikaitkan dengan masa tanam atau faktor cuaca yang kurang mendukung. Hal ini menunjukkan bahwa produksi padi di Sulawesi Selatan sangat dipengaruhi oleh faktor musiman.

3.2 Seasonal ARIMA

Plot pada Gambar 2. menunjukkan bahwa pola data *time series* produksi padi dari waktu ke waktu cenderung membentuk pola musiman. Hal ini menunjukkan bahwa data dapat dianalisis dengan metode ARIMA musiman atau biasa disebut SARIMA (*Seasonal Autoregressive In Moving Average*). Sebelum melakukan identifikasi model terlebih dahulu dilakukan uji kestasioneran yaitu data harus stasioner dalam rata-rata dan *varians*.


3.2.1 Uji Kestasioneran Data

Data yang digunakan perlu diuji kestasionerannya terhadap *varians* menggunakan Transformasi Box-Cox. Kriteria pengambilan keputusannya adalah jika nilai *rounded value* sama dengan 1 maka data sudah stasioner dalam *varians*.




Gambar 3. Plot data Box-Cox Jumlah Produksi Padi

Berdasarkan Gambar 3, nilai transformasi Box-Cox sebesar 0.00 yang menunjukkan bahwa data masih belum stasioner dalam variansi. Oleh karena itu, diperlukan transformasi lanjutan pada data. Plot hasil transformasi pertama dapat dilihat pada Gambar 4.




Gambar 4. Plot data Box-Cox Transformasi Pertama

Berdasarkan Gambar 4, setelah menerapkan transformasi pertama, nilai transformasi Box-Cox mencapai 1, yang menunjukkan bahwa data telah signifikan dan stasioner dalam variansi. Selanjutnya, kestasioneran dalam rata-rata diuji dengan menerapkan *differencing* pertama pada data yang telah ditransformasi. Data dianggap stasioner dalam rata-rata jika fluktuasinya berkisar di sekitar nilai rata-rata yang konstan. Untuk mengevaluasi kestasioneran rata-rata, dapat dilakukan analisis melalui plot ACF (*Autocorrelation Function*). Visualisasi plot ACF dapat dilihat pada Gambar 5 berikut:




Gambar 5. Plot ACF dan PACF

Gambar 5 memperlihatkan bahwa plot ACF meluruh secara lambat, menandakan data tidak stasioner dalam rata-rata. Oleh karena itu, diperlukan proses *differencing* untuk menstabilkan data. Penerapan *differencing* musiman dan nonmusiman diperlukan untuk mengatasi keberadaan komponen musiman dalam data, sehingga kestasioneran dalam rata-rata dapat tercapai. Setelah proses ini dilakukan, evaluasi ulang kestasioneran data dilakukan dengan menganalisis pola pada plot deret waktu serta plot autokorelasi (ACF).



Gambar 6. Plot Data setelah *Differencing* Nonmusiman dan Musiman



Gambar 7. Plot ACF dan PACF setelah *Differencing*

Seperti yang ditampilkan pada Gambar 6, plot data *time series* produksi padi dari Januari 2019 hingga Desember 2023 menunjukkan bahwa setelah dilakukan *differencing*,

pola yang terbentuk cenderung horizontal dan bergerak di sekitar rata-rata yang konstan. Hal ini mengindikasikan bahwa data telah stasioner dalam *mean*.

Plot ACF pada Gambar 7. menunjukkan bahwa tidak terdapat penurunan secara perlahan, yang mengindikasikan bahwa komponen tren dalam data telah hilang. Oleh karena itu, dapat disimpulkan bahwa data telah stasioner dalam *mean*.

3.2.2 Identifikasi Model Sementara

Jika data telah stasioner baik terhadap rata-rata maupun variansi, maka dapat diperoleh model sementara berdasarkan hasil uji data. Identifikasi model sementara dapat dilihat berdasar lag yang *cuts off* ataupun *dies down* pada diagram ACF dan PACF yang telah stasioner. Identifikasi model sementara dapat dilihat pada Gambar 7. Untuk model nonmusiman, plot ACF *cuts off* setelah lag pertama sehingga dapat diprediksi sebagai MA(1), dan plot PACF juga *cuts off* setelah lag pertama sehingga dapat diprediksi sebagai model AR(1). *Differencing* nonmusiman dilakukan sebanyak 1 kali. Sedangkan untuk model musiman, pada plot PACF terdapat lag ke-24 yang keluar melewati batas, maka nilai $P = 1$. Pada plot ACF lag ke-24 melewati garis batas, sehingga nilai $Q = 1$. *Differencing* musiman dilakukan sebanyak 1 kali, maka nilai $D = 1$.

Berdasarkan penjelasan mengenai model untuk bagian nonmusiman dan musiman pada ACF dan PACF diperoleh model SARIMA sementara yang mungkin adalah SARIMA(0,1,1)(1,1,0)¹², SARIMA(1,1,1)(1,1,0)¹², SARIMA(1,1,0)(1,1,0)¹², dan SARIMA(1,1,1)(1,1,1)¹². Apabila model awal telah diperoleh, kemudian dilakukan pengembangan model atau dimodifikasi menjadi beberapa model dan dilakukan estimasi model parameter. Maka diperoleh model yang parameternya signifikan dan memiliki nilai AIC terkecil yaitu model SARIMA (1,1,0)(1,1,0)¹².

3.2.3 Uji Asumsi Residual

Uji asumsi residual ini terdiri atas uji diagnostik dan uji distribusi normal. Uji diagnostik digunakan untuk melihat apakah residual dari model bersifat *white noise* atau tidak. Pengecekan diagnostik dapat dilakukan dengan menggunakan Ljung-Box Test. Nilai *p-value* yang diperoleh dari uji diagnostik adalah $0.99 > \alpha$ (0.05). Sehingga dengan menggunakan tingkat kepercayaan 95% dapat disimpulkan bahwa tidak terdapat autokorelasi antar residual.

Uji *white noise* telah terpenuhi selanjutnya dilakukan pengujian residual berdistribusi normal pada model dengan menggunakan uji *Kolmogorov-Smirnov*. Berdasarkan uji diperoleh nilai *p-value* yaitu > 0.15 yang lebih besar dari α (0.05), sehingga dapat disimpulkan bahwa data memenuhi asumsi distribusi normal. Berdasarkan hasil uji asumsi residual yang telah dilakukan, model terbaik yaitu SARIMA (1,1,0)(1,1,0)¹², memenuhi kedua asumsi yang diuji. Oleh karena itu, model ini layak digunakan untuk peramalan.

3.2.4 Hasil *Forecasting* Metode SARIMA

Hasil peramalan untuk 12 periode berikutnya, yaitu Januari hingga Desember 2024 dengan menggunakan persamaan model SARIMA(1,1,0)(1,1,0)¹² dapat dilihat pada Tabel 1 berikut.

Tabel 1. Hasil *Forecasting* SARIMA

Tahun	Bulan	Produksi Padi (ribu ton)	Hasil Peramalan
2024	Januari	34	35.70
	Februari	24	23.85
	:	:	:
	November	394	385.73
	Desember	162	143.23

3.3 *Extreme Learning Machine*

3.3.1 Normalisasi Data

Dalam proses *forecasting* menggunakan metode ELM, langkah pertama yang harus dilakukan adalah normalisasi data. Pada penelitian ini digunakan metode *Min-Max Normalization* untuk menyesuaikan skala data. Hasil normalisasi data dengan metode tersebut ditampilkan pada Tabel 2 berikut.

Tabel 2. Hasil Normalisasi Data

Tahun	Bulan	Produksi Padi (ribu ton)	Normalisasi
2018	Januari	410	0.346
	Februari	330	0.269
:	:	:	:
:	:	:	:
2023	Desember	139	0.085

3.3.2 Proses *Training*

Sebelum melakukan peramalan, dilakukan proses *training* dengan arsitektur jaringan yang terdiri dari 12 *input layer*, 56 *hidden layer*, dan 1 *output layer* untuk memprediksi jumlah produksi padi di Sulawesi Selatan. Data yang telah dinormalisasi digunakan sebagai *input* dengan 12 *layer*, yaitu X_1, X_2, X_3 , hingga X_{12} . Pola *input* data *training* yang telah dinormalisasi dan dibentuk dapat dilihat pada Tabel 3.


Tabel 3. Data Proses *Training*

Data	Target	Node Input				
i	t_i	X_1	X_2		X_{11}	X_{12}
1	0.039	0.096	0.154		0.269	0.346
2	0.135	0.039	0.096		0.625	0.269
:	:	:	:		:	:
:	:	:	:		:	:

71	0.313	0.347	0.688		0.081	0.327
72	0.085	0.313	0.347		0.057	0.081

Tabel 3. menampilkan data yang digunakan dalam proses *training*. Nilai X_1, X_2 , hingga X_{12} merepresentasikan jumlah *node* pada *input layer*, sedangkan t_i adalah target yang digunakan untuk menghitung keluaran *hidden layer* selama *training*. Karena jumlah *node input* sebanyak 12, nilai target dimulai dari data ke-13. Sebagai ilustrasi, pola data pertama terdiri dari *input* X_{12} , yaitu data ke-1 yang telah dinormalisasi dengan nilai 0.346, X_{11} sebagai data ke-2 dengan nilai 0.269, dan seterusnya hingga X_1 , yaitu data ke-12 dengan nilai 0.096, sementara targetnya adalah data ke-13 dengan nilai 0.039. Begitu pula untuk pola data berikutnya, di mana pada pola kedua, nilai X_{12} dimulai dari data ke-2 hingga X_1 , yang merupakan data ke-13, dengan target pada data ke-14, dan proses ini berlanjut hingga pola data ke-56.

Arsitektur jaringan ini diperoleh dengan bantuan *software* R, dan visualisasinya dapat dilihat pada Gambar 8. Jaringan ELM yang digunakan memiliki 12 *node* pada *input layer*, yang merepresentasikan jumlah bulan dalam data *input*. Selama proses *training*, bobot *input* diinisialisasi secara acak untuk menghitung keluaran pada *hidden layer*. Dengan 12 *node input* dan 56 *hidden layer*, jumlah bobot input yang dihasilkan mencapai 672. Setiap *node input* terhubung ke seluruh *node* pada *hidden layer*, masing-masing dengan 56 bobot.



Gambar 8. Arsitektur Jaringan ELM

Diketahui bahwa *node input* X_1 memiliki 56 bobot, yaitu $W_{1.1}, W_{1.2}, W_{1.3}$, hingga $W_{1.56}$, dan berlaku hal yang sama untuk *node input* lainnya. Selanjutnya, perhitungan pada *hidden layer* dilakukan dengan menerapkan fungsi aktivasi untuk menghasilkan *output* dari *hidden layer*, yang kemudian digunakan untuk menentukan bobot antara *hidden layer* dan *output layer*. Setelah memperoleh bobot antara *hidden layer* dan *output*

layer maka dilakukan perhitungan pada *output layer* untuk hasil prediksinya. Berikut adalah output dari proses *training* yang berupa hasil prediksi, dapat dilihat pada Tabel 4.

Tabel 4. Hasil Prediksi

Tahun	Bulan	Produksi Padi (ribu ton)	Prediksi
2019	Januari	90	137.549
	Februari	190	234.516
⋮	⋮	⋮	⋮
2023	November	376	372.081
	Desember	139	221.660

3.3.3 Hasil *Forecasting* Metode ELM

Setelah proses *training* dilakukan dan mendapatkan hasil prediksi, selanjutnya adalah dilakukan *forecasting* menggunakan metode ELM. Tabel 5 merupakan hasil *forecasting* 12 periode yang telah dilakukan menggunakan metode ELM dengan menggunakan 12 *input layer* dan 56 *hidden layer*.

Tabel 5. Hasil *Forecasting* ELM

Tahun	Bulan	Produksi Padi (ribu ton)	Hasil Peramalan
2024	Januari	34	36.266
	Februari	24	25.275
	⋮	⋮	⋮
	November	394	366.635
	Desember	162	223.150


3.4 Uji Validitas dan Perbandingan Metode

Pada tahap ini, dilakukan pengujian ketepatan model atau validasi hasil peramalan menggunakan nilai MAPE untuk masing-masing metode. Dengan membandingkan nilai MAPE, dapat ditentukan metode yang lebih akurat dalam memprediksi jumlah produksi padi di Sulawesi Selatan. Hasil perhitungan nilai MAPE dari peramalan dapat dilihat pada Tabel 6.

Tabel 6. Perbandingan Metode

Periode ke	Data <i>Testing</i>	Hasil Peramalan		MAPE	
		SARIMA	ELM	SARIMA	ELM
73 (Jan-2024)	34	35.70	36.266	19.937%	21.632%
74 (Feb-2024)	24	23.85	25.275		
⋮	⋮	⋮	⋮		
83 (Nov-2024)	394	385.73	366.635		
84 (Des-2024)	161	143.23	223.150		

Berdasarkan hasil perhitungan MAPE pada Tabel 6, metode SARIMA memiliki nilai 19.937%, yang lebih rendah dibandingkan metode ELM dengan 21.632%, sehingga lebih baik digunakan dalam *forecasting* jumlah produksi padi di Sulawesi Selatan. Model peramalan dikategorikan sangat baik jika $MAPE < 10\%$, dan baik jika berada dalam rentang 10%–20%. Karena nilai MAPE dari metode SARIMA lebih kecil dibandingkan metode ELM dan masih berada dalam kategori baik, maka metode ini lebih direkomendasikan dalam studi kasus ini. Grafik perbandingan antara data aktual dan hasil prediksi menggunakan SARIMA ditampilkan pada Gambar 10.



Gambar 9. Grafik Data Aktual vs Prediksi Metode SARIMA

Hasil prediksi digambarkan dengan garis yang berwarna merah sebagaimana pada Gambar 9, sedangkan data aktual yang berwarna biru. Dapat dilihat bahwa garis peramalan yang berwarna merah menunjukkan bahwa pola tersebut mirip dengan pola pada musim-musim sebelumnya.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode SARIMA lebih baik dibandingkan dengan metode ELM dalam memprediksi jumlah produksi padi di Sulawesi Selatan selama 12 periode ke depan. Hal ini dibuktikan dengan nilai MAPE metode SARIMA sebesar 19.937%, yang lebih kecil dibandingkan metode ELM dengan nilai MAPE sebesar 21.632%. Dengan demikian, metode SARIMA menunjukkan tingkat akurasi yang lebih tinggi dalam peramalan jumlah produksi padi di Sulawesi Selatan.

Daftar Pustaka

- [1] Badan Pusat Statistik Provinsi Sulawesi Selatan. *Luas Panen dan Produksi Padi di Sulawesi Selatan 2024*. BPS Sulawesi Selatan, 2024.
- [2] Auliya, D., Rosandi, A. H., & Subroto, W. T. Analisis Perubahan Iklim terhadap Produktivitas Padi di Jawa Timur. *Diponegoro Journal of Economics*, 13(3), 2024.

- [3] Prianda, B. G., & Widodo, E. Perbandingan Metode *Seasonal ARIMA* dan *Extreme Learning Machine* Pada Peramalan Jumlah Wisatawan Mancanegara ke Bali. *BAREKENG Jurnal Ilmu Matematika dan Terapan*, 15(4), 2021.
- [4] Ruhiat, D., & Effendi, A. Pengaruh Faktor Musiman pada Pemodelan Deret Waktu untuk Peramalan Debit Sungai dengan Metode SARIMA. *Jurnal Teori dan Riset Matematika*, 2(2), 2018.
- [5] Kusuma, W., Setiawan, R. N., & Widiyanti, N. M. Model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) untuk Memprediksi Jumlah Produksi Beras di Provinsi Nusa Tenggara Barat. *Agroteksos*, 34(3), 2024.
- [6] Kurniasih, I. H., Furqon, M. T., & Adinugroho, S. Prediksi Pertumbuhan Penduduk di Kota Malang menggunakan Metode Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 10(1), 2024.
- [7] Febiola, A., Dewi, A., & Fazarin, F. M. Perbandingan Metode ARIMA dan SARIMA Dalam Peramalan Jumlah Penumpang Bandara Provinsi Kepulauan Bangka Belitung. *Jambura Journal of Mathematics*, 6(2), 2024.
- [8] Susanti, N. E., Saputra, R., & Situmorang, I. A. Perbandingan Metode SARIMA, *Double Exponential Smoothing* dan *Holt-Winter Additive* dalam Peramalan *Retail Sales* Mobil Honda. *Jurnal Sains Matematika dan Statistika*, 4(2), 2024.
- [9] Alwi, W., Nurfadilah, K., & Munira. Penerapan Metode SARIMA untuk Peramalan Jumlah Pengunjung Wisata Taman Nasional Bantimurung Bulusaraung Maros. *Journal of Mathematics: Theory and Applications*, 3(1), 2021.
- [10] Pradhisa, K. C., & Yotenka, R. Penerapan Metode *Extreme Learning Machine* (ELM) untuk Meramalkan Produksi Air Minum dan Air yang Dijual di Kota Yogyakarta Tahun 2023. *Emerging Statistics and Data Science Journal*, 2(2), 2024.
- [11] Ardian, I. Y., Rismawan, T., & Midyanti, D. M. Penerapan Metode *Extreme Learning Machine* untuk Peramalan Jumlah Kepadatan Penduduk di Kalimantan Barat. *Coding: Jurnal Komputer dan Aplikasi*, 7(3), 2019.
- [12] Paudi, P. I., Furqon, M. T., & Sutrisno. Implementasi Metode *Extreme Learning Machine* (ELM) untuk Memprediksi Jumlah Debit Air yang Layak Didistribusi (Studi Kasus: PDAM Kabupaten Gowa Makassar). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 4(3), 2020.
- [13] Irawan, M. Z., Akil, Y. S., & Gunadin, I. C. Peramalan Beban Listrik Kota Maros Berbasis *Extreme Learning Machine* (ELM). *Jurnal EKSITASI*, 1(2), 2022.