



***Corresponding author:** Meiliyani Siringoringo, Laboratory of Economic and Business Statistics, Department of Mathematics, Faculty of Mathematics and Natural Sciences, Mulawarman University, Indonesia.

E-mail:
meiliyanisiringoringo@fmipa.unmul.ac.id

RESEARCH ARTICLE

Forecasting the Total of Paddy Production in Indonesia Using Time Series Regression Model

Ahmad Rizky Kesuma¹, Meiliyani Siringoringo^{2*}, Siti Mahmuda³

¹Statistics Study Program, Department of Mathematics, Faculty of Mathematics and Natural Sciences, Mulawarman University, Indonesia.

²Laboratory of Economic and Business Statistics, Department of Mathematics, Faculty of Mathematics and Natural Sciences, Mulawarman University, Indonesia. Email: meiliyanisiringoringo@fmipa.unmul.ac.id

³Laboratory of Computational Statistics, Department of Mathematics, Faculty of Mathematics and Natural Sciences, Mulawarman University, Indonesia.

Abstract: Time series regression (TSR) is a forecasting model that can be used when there are trend and seasonal patterns. Paddy is a source of rice, which is a staple food for the Indonesian people. Paddy has a seasonal pattern because its cultivation depends on the rainy season. This study forecasts the amount of paddy production in Indonesia based on monthly data of paddy production in Indonesia to determine the production of paddy in 2023 and to assess the ability of the TSR model to forecast paddy production. The results showed that paddy production in 2023 is forecasted to have the same seasonal pattern as in previous years and reaches its peak production in April at 8.699 million tons. The TSR model of paddy production has a mean absolute percentage error (MAPE) of 8.654% indicating a very good forecasting accuracy.

Keywords: Forecasting, Paddy, Seasonal, Time series regression

1. INTRODUCTION

Peramalan adalah kegiatan memperkirakan suatu nilai atau kejadian di masa depan dengan menggunakan data masa lalu (Jamila dkk., 2021). Peramalan dapat dilakukan dengan analisis runtun waktu yaitu sebuah cara untuk mengungkapkan informasi yang ada di dalam data runtun waktu dan juga untuk meramalkan kejadian di masa depan dengan akurasi yang baik (Andronov, 2020). Langkah penting yang perlu dilakukan dalam melakukan analisis runtun waktu yaitu membuat grafik persebaran untuk melihat pola yang terbentuk, beberapa pola yang sering muncul saat melakukan peramalan adalah pola horizontal, siklis, tren dan musiman (Makridakis dkk., 1997). Metode peramalan yang dapat digunakan ketika terdapat pola tren maupun musiman adalah *time series regression* (TSR) (Dani dkk., 2023).

Time series regression pada dasarnya sama saja seperti regresi pada umumnya terutama regresi *dummy* (Arumsari & Dani, 2021). Model TSR digunakan untuk melihat hubungan antara variabel respon dengan satu atau beberapa variabel prediktor yang berupa fungsi waktu (Dani dkk., 2023). Pada penelitian yang dilakukan oleh Dani dkk. (2023), terdapat beberapa variabel prediktor yang bisa ditambahkan ke dalam TSR adalah variabel tren, variabel *dummy* berupa musiman dan efek variasi kalender.

Terdapat beberapa penelitian terdahulu yang menggunakan metode TSR. melakukan peramalan menggunakan TSR dalam meramalkan tren pencarian kata kunci Sarung Wadimor di Indonesia pada data *Google Trends*, hasil dari penelitian tersebut didapatkan bahwa pendekatan TSR dengan variabel tren, musiman dan efek variasi kalender memiliki



keakuratan yang lebih tinggi dibandingkan *Autoregressive Integrated Moving Average* (ARIMA) yaitu TSR memiliki *Root Mean Square Error* (RMSE) sebesar 9,413 sedangkan ARIMA sebesar 10,624 (Dani dkk., 2023). Wirdyacharya dan Prastuti (2022) juga melakukan penelitian menggunakan TSR terhadap data musiman permintaan semen di suatu perusahaan, hasil penelitian mendapatkan TSR memiliki nilai RMSE sebesar 49,405. (Arumsari dan Dani (2021) melakukan pemodelan TSR terhadap data musiman penumpang pesawat di Amerika Serikat sebagai model awal dalam pembentukan model TSR-ARIMA, model awal TSR dengan variabel tren dan musiman menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 7,902% yang menunjukkan hasil peramalan yang sangat akurat.

Penerapan model TSR pada penelitian terdahulu menunjukkan bahwa model TSR sangat baik digunakan dalam memodelkan data berpola musiman. Salah satu data yang berpola musiman adalah produksi padi. Hal ini disebabkan oleh penanaman padi yang bergantung pada musim hujan (Surmaini & Syahbuddin, 2016). Padi merupakan komoditas yang sangat penting bagi Indonesia. Padi berkaitan erat dengan ketahanan pangan di Indonesia karena padi merupakan penghasil beras yang merupakan sumber makanan pokok di Indonesia (Suwarno, 2010).

Berdasarkan Indeks Ketahanan Pangan Global atau *Global Food Security Index* (GFSI) tahun 2022, Indonesia menduduki peringkat 63 dari 113 negara dengan nilai indeks sebesar 60,2, nilai tersebut masih berada di bawah rata-rata global yaitu sebesar 62,2, hal ini cukup disayangkan mengetahui sebagaimana Indonesia terkenal sebagai negara agraris. Salah satu faktor penyusun GFSI adalah *availability* yaitu adanya ketersediaan pangan yang berkaitan dengan produksi pangan. Suwarno (2010) menjelaskan bahwa salah satu upaya untuk meningkatkan ketahanan pangan adalah dengan meningkatkan produksi pangan yaitu padi (Suwarno, 2010). Pemerintah Indonesia selalu berupaya meningkatkan produksi padi dari tahun ke tahun. Hal ini disampaikan oleh Menteri Pertanian Indonesia Syahrul Yasin Limpo dalam Rapat Kerja bersama komisi V DPR RI pada Senin, 11 April 2022. Beliau mengusung target produksi tahun 2023 untuk komoditas padi sebesar 56,08 juta ton. Target produksi padi sebesar 56,08 juta ton untuk Tahun 2023 merupakan peningkatan sebesar 1,33 juta ton dari produksi padi Tahun 2022 yang dicatat oleh Badan Pusat Statistik yaitu 54,75 juta ton.

Penelitian ini akan menggunakan model TSR untuk meramalkan produksi padi Indonesia periode Januari 2023 hingga Desember 2023 untuk mengetahui hasil dan pola produksi padi di tahun tersebut. Pada penerapan model TSR cenderung menghasilkan model yang tidak memenuhi asumsi residual sehingga pada penelitian ini akan dilakukan penambahan variabel prediktor yaitu *lag*, hal ini sudah pernah dilakukan oleh Suhartono dkk. (2010). Hasil peramalan yang diperoleh mampu memberikan gambaran mengenai produksi padi di Indonesia dan juga mampu mengukur kapasitas model TSR dalam memodelkan data produksi padi.

2. Literature Review

2.1 Pemodelan Time Series Regression

Model *time series regression* (TSR) pada dasarnya sama saja seperti regresi pada umumnya terutama regresi variabel *dummy*. Model TSR dapat digunakan ketika terdapat pola tren maupun musiman. Model TSR untuk data yang memiliki pola tren dan musiman adalah sebagai berikut (Hyndman & Athanasopoulos, 2018):

$$Z_t = \beta_0 + \beta_1 T_t + \beta_2 D_{1,t} + \beta_3 D_{2,t} + \dots + \beta_{s+1} D_{s,t} + \varepsilon_t, t = 1, 2, 3, \dots, n \quad (1)$$

dengan:

Z_t : data pengamatan periode ke- t

β_0 : konstanta

β_1 : koefisien regresi variabel tren

T_t : data variabel tren periode ke- t

β_{j_1} : koefisien regresi variabel *dummy* musiman ke- $(j_1 - 1)$ dengan $j_1 = 2, 3, 4, \dots, s + 1$

$D_{i,t}$: data variabel *dummy* musiman ke- i periode ke- t dengan $i = 1, 2, 3, \dots, s$



ε_t : data residual periode ke- t
 n : banyaknya data pengamatan

Apabila asumsi *white noise* tidak terpenuhi maka dapat diatasi dengan menambahkan *lag* sebagai variabel prediktor dalam model TSR adapun modelnya adalah sebagai berikut (Suhartono dkk., 2010):

$$Z_t = \beta_0 + \beta_1 T_t + \beta_2 D_{1,t} + \beta_3 D_{2,t} + \cdots + \beta_{s+1} D_{s,t} + \beta_{s+2} Z_{t-p} + \varepsilon_t, t = 1, 2, 3, \dots, n \quad (2)$$

dimana p adalah *lag* yang nilai korelasi pada grafik *autocorrelation function* (ACF) dan *partial autocorrelation function* dari residual model TSR berada di luar interval kepercayaan 95%.

2.2 Estimasi dan Signifikansi Parameter

Estimasi parameter model TSR sama saja seperti regresi linier di mana dapat dilakukan dengan metode *ordinary least square* (OLS) yaitu metode yang meminimumkan jumlah kuadrat *error* (Makarti & Karim, 2017). Uji signifikansi parameter secara simultan dilakukan untuk mengetahui apakah variabel prediktor secara simultan berpengaruh terhadap variabel respon. Dengan menggunakan persamaan (3) sebagai contoh, maka pengujiannya adalah sebagai berikut (Montgomery dkk., 2008):

Hipotesis

$$H_0 : \beta_1 = \beta_2 = \beta_3 = \cdots = \beta_{s+1} = 0$$

$$H_1 : \text{Minimal ada satu } \beta_{i_1} \neq 0, i_1 = 1, 2, 3, \dots, s + 1$$

Statistik Uji

$$F_{hitung} = \frac{SSR / (s + 1)}{SSE / (n - (s + 1) - 1)} \quad (3)$$

dengan SSR dan SSE dapat dinyatakan dalam persamaan berikut

$$SSR = \sum_{t=1}^n (\hat{Z}_t - \bar{Z})^2 \quad (4)$$

$$SSE = \sum_{t=1}^n (Z_t - \hat{Z}_t)^2 \quad (5)$$

di mana $\bar{Z}$ adalah rata-rata data pengamatan. H_0 ditolak jika $F_{hitung} > F_{\alpha; db_1; db_2}$ atau $p\text{-value} < \alpha$ dimana α adalah taraf signifikansi, $db_1 = s + 1$, dan $db_2 = n - (s + 1) - 1$.

Uji signifikansi parameter secara parsial dilakukan untuk mengetahui apakah variabel prediktor secara parsial berpengaruh terhadap variabel respon. Dengan menggunakan persamaan (1) sebagai contoh, maka pengujiannya adalah sebagai berikut (Montgomery dkk., 2008):

Hipotesis

$$H_0 : \beta_{j_2} = 0$$

$$H_1 : \beta_{j_2} \neq 0, j_2 = 0, 1, 2, \dots, s + 1$$

Statistik Uji

$$t_{hitung} = \frac{\hat{\beta}_{j_2}}{se(\hat{\beta}_{j_2})} \quad (6)$$

dengan:

$\hat{\beta}_{j_2}$: Estimator parameter regresi ke- j_2

$se(\hat{\beta}_{j_2})$: standar *error* estimator parameter ke- j_2

H_0 ditolak jika $|t_{hitung}| > t_{\alpha/2; n-(s+1)-1}$ atau $p\text{-value} < \alpha$ dimana α adalah taraf signifikansi.

2.3 Backward Elimination

Backward elimination adalah metode pemilihan variabel prediktor yang dilakukan dengan cara mengeluarkan variabel prediktor yang paling tidak signifikan yang ditunjukkan oleh nilai $p\text{-value}$ terbesar yang lebih besar dari taraf signifikansi (Maulidina dkk., 2021).

2.4 Pengujian Asumsi Residual dan Ukuran Akurasi Peramalan

Residual model TSR harus memenuhi asumsi *white noise* yaitu berdistribusi normal dan independen. Uji normalitas residual dapat menggunakan uji *Kolmogorov – Smirnov* dan uji independensi residual dapat menggunakan uji *Ljung – Box* (Wiridyachya & Prastuti, 2022). Terdapat beberapa ukuran akurasi peramalan yang sering digunakan seperti *mean absolute percentage error* (MAPE), *mean square of error* (MSE), dan *root mean square of error* (RMSE). Pada penelitian ini digunakan ukuran akurasi peramalan yaitu MAPE yang dihitung berdasarkan nilai mutlak dari *error* pada setiap periode yang kemudian dibagi dengan nilai data aktual pada periode tersebut (Khair dkk., 2017).


3. Research Method and Materials

Material yang digunakan pada penelitian ini adalah data produksi padi bulanan di Indonesia dari Januari 2018 hingga Desember 2022. Adapun langkah-langkah penelitiannya adalah sebagai berikut:

1. Melakukan analisis statistika deskriptif dengan menampilkan grafik runtun waktu variabel respon.
2. Membentuk model TSR tren dan musiman. Adapun model TSR pola tren dan musiman adalah sebagai berikut
3. Melakukan estimasi parameter dengan metode *ordinary least square* (OLS).
4. Melakukan uji signifikansi simultan dan parsial.
5. Melakukan seleksi variabel menggunakan metode *backward elimination* jika terdapat parameter yang tidak signifikan secara parsial. Jika dilakukan *backward elimination* maka dilanjutkan dengan mengulangi langkah 3 dan 4.
6. Melakukan pengujian asumsi residual yaitu normalitas residual dan independensi residual.
7. Melakukan penambahan *lag* sebagai variabel prediktor jika asumsi residual tidak terpenuhi.
8. Melakukan prediksi dan peramalan menggunakan model TSR.
9. Menghitung nilai *mean absolute percentage error* (MAPE) model TSR.

4. Results and Discussion

Langkah awal dalam pemodelan *time series regression* (TSR) adalah membuat grafik runtun waktu untuk melihat pola yang terbentuk.



Gambar 1: Produksi Padi di Indonesia Tahun 2018-2022

Pada Gambar 1, terlihat bahwa data produksi padi Indonesia dari Januari 2018 hingga Desember 2022 memiliki pola musiman yang berulang setiap tahunnya sehingga dilakukan pemodelan TSR menggunakan *dummy* musiman yaitu $D_1, D_2, D_3, \dots, D_{12}$ (D_1 adalah Bulan Januari, D_2 adalah Bulan Februari dan seterusnya) dan variabel tren (T) sebagai prediktor. Variabel respon jumlah produksi padi dilambangkan dengan (Z). Adapun variabel D_4 yaitu variabel *dummy* Bulan April digunakan sebagai *reference*.

$$\begin{aligned} Z_t = & \beta_0 + \beta_1 T_t + \beta_2 D_{1,t} + \beta_3 D_{2,t} + \beta_4 D_{3,t} + \beta_5 D_{5,t} \\ & + \beta_6 D_{6,t} + \beta_7 D_{7,t} + \beta_8 D_{8,t} + \beta_9 D_{9,t} + \beta_{10} D_{10,t} \\ & + \beta_{11} D_{11,t} + \beta_{12} D_{12,t} + \varepsilon_t \end{aligned} \quad (7)$$

kemudian dilakukan estimasi parameter sehingga didapatkan model berikut

$$\begin{aligned} \hat{Z}_t = & 8,540 - 0,006T_t - 6,186D_{1,t} - 4,414D_{2,t} \\ & + 0,502D_{3,t} \\ & - 3,643D_{5,t} - 4,196D_{6,t} - 3,391D_{7,t} - 3,335D_{8,t} \\ & - 3,630D_{9,t} - 4,523D_{10,t} - 5,360D_{11,t} - 6,476D_{12,t} \end{aligned} \quad (8)$$

Selanjutnya dilakukan uji simultan sehingga didapatkan F_{hitung} sebesar 34,75 yang lebih besar dari $F_{0,05;12;47}$ sebesar 1,96 dan p -value sebesar $2,2 \times 10^{-16}$ yang lebih kecil dari taraf signifikansi 0,05 yang menunjukkan bahwa secara simultan seluruh parameter berpengaruh signifikan pada model. Kemudian dilakukan uji parsial dengan nilai $t_{0,025;47}$ sebesar 2,011.

Tabel 1: Uji parsial

Parameter	t_{hitung}	p -value	Keputusan
β_0	22,223	$< 2 \times 10^{-16}$	H_0 ditolak
β_1	1,070	0,29	H_0 gagal ditolak
β_2	12,599	$< 2 \times 10^{-16}$	H_0 ditolak
β_3	8,992	$8,79 \times 10^{-12}$	H_0 ditolak
β_4	1,023	0,311	H_0 gagal ditolak
β_5	7,424	$1,87 \times 10^{-9}$	H_0 ditolak
β_6	8,549	$3,91 \times 10^{-11}$	H_0 ditolak
β_7	6,906	$1,14 \times 10^{-8}$	H_0 ditolak
β_8	6,789	$1,71 \times 10^{-8}$	H_0 ditolak
β_9	7,384	$2,15 \times 10^{-9}$	H_0 ditolak
β_{10}	9,193	$4,50 \times 10^{-12}$	H_0 ditolak

β_{11}	10,885	$1,93 \times 10^{-14}$	H_0 ditolak
β_{12}	13,137	$< 2 \times 10^{-16}$	H_0 ditolak

Berdasarkan Tabel 1, secara parsial masih terdapat parameter yang tidak berpengaruh signifikan yaitu β_1 dan β_4 sehingga perlu dilakukan seleksi variabel. Pada penelitian ini digunakan seleksi variabel yaitu *backward elimination*. *Backward elimination* adalah metode pemilihan variabel prediktor yang dilakukan dengan cara mengeluarkan variabel prediktor yang paling tidak signifikan yang ditunjukkan oleh nilai p – *value* terbesar yang lebih besar dari taraf signifikansi (α).

Tabel 1 menunjukkan bahwa p -*value* terbesar dimiliki oleh parameter β_4 yang merupakan koefisien dari D_3 maka variabel D_3 akan dikeluarkan dan didapatkan model sebagai berikut.

$$Z_t = \beta_0 + \beta_1 T_t + \beta_2 D_{1,t} + \beta_3 D_{2,t} + \beta_5 D_{5,t} + \beta_6 D_{6,t} + \beta_7 D_{7,t} + \beta_8 D_{8,t} + \beta_9 D_{9,t} + \beta_{10} D_{10,t} + \beta_{11} D_{11,t} + \beta_{12} D_{12,t} + \varepsilon_t \quad (9)$$

Lalu mengestimasi parameter menggunakan OLS.

$$\hat{Z}_t = 8,794 - 0,006T_t - 6,437D_{1,t} - 4,665D_{2,t} - 3,894D_{5,t} - 4,447D_{6,t} - 3,642D_{7,t} - 3,586D_{8,t} - 3,880D_{9,t} - 4,773D_{10,t} - 5,611D_{11,t} - 6,726D_{12,t} \quad (10)$$

Kemudian dilakukan uji simultan sehingga didapatkan F_{hitung} sebesar 37,77 yang lebih besar dari $F_{0,05;11;48}$ sebesar 1,99 dan p -*value* sebesar $2,2 \times 10^{-16}$ yang lebih kecil dari taraf signifikansi 0,05 yang menunjukkan bahwa secara simultan seluruh parameter berpengaruh signifikan pada model. Kemudian dilakukan uji parsial dengan nilai $t_{0,025;48}$ sebesar 2,010.

Tabel 2: Uji parsial iterasi *backward elimination* pertama

Parameter	$ t_{hitung} $	p - <i>value</i>	Keputusan
β_0	29,879	$< 2 \times 10^{-16}$	H_0 ditolak
β_1	1,082	0,285	H_0 gagal ditolak
β_2	15,132	$< 2 \times 10^{-16}$	H_0 ditolak
β_4	10,970	$1,12 \times 10^{-14}$	H_0 ditolak
β_5	9,157	$4,17 \times 10^{-12}$	H_0 ditolak
β_6	10,453	$5,82 \times 10^{-14}$	H_0 ditolak
β_7	8,555	$3,23 \times 10^{-11}$	H_0 ditolak
β_8	8,418	$5,18 \times 10^{-11}$	H_0 ditolak
β_9	9,100	$5,05 \times 10^{-12}$	H_0 ditolak
β_{10}	11,182	$5,77 \times 10^{-15}$	H_0 ditolak
β_{11}	13,126	$< 2 \times 10^{-16}$	H_0 ditolak
β_{12}	15,711	$< 2 \times 10^{-16}$	H_0 ditolak

Berdasarkan Tabel 2, masih terdapat parameter yang tidak berpengaruh signifikan yaitu β_1 yang merupakan koefisien dari variabel tren maka variabel tren dikeluarkan dari model. Sehingga modelnya adalah sebagai berikut.

$$Z_t = \beta_0 + \beta_2 D_{1,t} + \beta_3 D_{2,t} + \beta_5 D_{5,t} + \beta_6 D_{6,t} + \beta_7 D_{7,t} + \beta_8 D_{8,t} + \beta_9 D_{9,t} + \beta_{10} D_{10,t} + \beta_{11} D_{11,t} + \beta_{12} D_{12,t} + \varepsilon_t \quad (11)$$

Lalu mengestimasi parameter menggunakan OLS.

$$\hat{Z}_t = 8,618 - 6,421D_{1,t} - 4,655D_{2,t} - 3,904D_{5,t} \quad (12)$$

$$-4,463D_{6,t} - 3,664D_{7,t} - 3,615D_{8,t} - 3,915D_{9,t} \\ -4,815D_{10,t} - 5,659D_{11,t} - 6,780D_{12,t}$$


Kemudian dilakukan uji simultan kembali sehingga didapatkan F_{hitung} sebesar 41,29 yang lebih besar dari $F_{0,05;10;49}$ sebesar 2,030 dan p -value sebesar $2,2 \times 10^{-16}$ yang lebih kecil dari taraf signifikansi 0,05 yang menunjukkan bahwa secara simultan seluruh parameter berpengaruh signifikan pada model. Kemudian dilakukan uji parsial dengan nilai $t_{0,025;49}$ sebesar 2,009.

Tabel 3: Uji parsial iterasi *backward elimination* kedua

Parameter	$ t_{hitung} $	p -value	Keputusan
β_0	35,047	$< 2 \times 10^{-16}$	H_0 ditolak
β_2	15,077	$< 2 \times 10^{-16}$	H_0 ditolak
β_4	10,930	$9,67 \times 10^{-15}$	H_0 ditolak
β_5	9,166	$3,34 \times 10^{-12}$	H_0 ditolak
β_6	10,479	$4,17 \times 10^{-14}$	H_0 ditolak
β_7	8,603	$2,23 \times 10^{-11}$	H_0 ditolak
β_8	8,487	$3,47 \times 10^{-11}$	H_0 ditolak
β_9	9,193	$3,04 \times 10^{-12}$	H_0 ditolak
β_{10}	11,305	$2,94 \times 10^{-15}$	H_0 ditolak
β_{11}	13,286	$< 2 \times 10^{-16}$	H_0 ditolak
β_{12}	15,920	$< 2 \times 10^{-16}$	H_0 ditolak


Berdasarkan Tabel 3 diketahui bahwa seluruh parameter berpengaruh signifikan secara parsial pada model maka dilanjutkan ke pengujian asumsi residual.


Pengujian normalitas residual menggunakan uji *Kolmogorov-Smirnov* mendapatkan p -value sebesar 0,897 yang lebih besar dari taraf signifikansi 0,05 yang berarti bahwa residual model TSR berdistribusi normal. Hasil pengujian independensi residual menggunakan uji *Ljung-Box* dapat dilihat pada gambar berikut



Gambar 2: P -value uji *Ljung-Box* model TSR

Pada Gambar 2, garis biru putus-putus adalah taraf signifikansi 0,05 dan terlihat masih terdapat lag yang nilai p -value berada di bawah 0,05 yang berarti bahwa terdapat otokorelasi antar residual model TSR. Otokorelasi residual dalam model TSR dapat diatasi dengan menambahkan lag yang keluar dari interval kepercayaan pada grafik *autocorrelation function* (ACF) atau *partial autocorrelation function* (PACF) yang dibuat dari residual model TSR ke dalam model TSR.





Gambar 3: Grafik (a) ACF dan (b) PACF dari residual model TSR

Berdasarkan Gambar 3, *lag* yang keluar dari interval kepercayaan adalah *lag* 2 dan 24 maka Z_{t-2} dan Z_{t-24} dimasukkan ke dalam model TSR sebagai berikut

$$\begin{aligned} Z_t = & \beta_0 + \beta_2 D_{1,t} + \beta_3 D_{2,t} + \beta_5 D_{5,t} + \beta_6 D_{6,t} + \beta_7 D_{7,t} \\ & + \beta_8 D_{8,t} + \beta_9 D_{9,t} + \beta_{10} D_{10,t} + \beta_{11} D_{11,t} + \beta_{12} D_{12,t} \\ & + \beta_{13} Z_{t-2} + \beta_{14} Z_{t-24} + \varepsilon_t \end{aligned} \quad (13)$$

Lalu mengestimasi parameter menggunakan OLS.

$$\begin{aligned} \hat{Z}_t = & 13,763 - 9,678 D_{1,t} - 7,709 D_{2,t} - 3,635 D_{5,t} - 4,972 D_{6,t} \\ & - 4,853 D_{7,t} - 4,935 D_{8,t} - 4,951 D_{9,t} - 6,280 D_{10,t} \\ & - 7,667 D_{11,t} - 9,693 D_{12,t} - 0,317 Z_{t-2} - 0,515 Z_{t-24} \end{aligned} \quad (14)$$


kemudian dilakukan uji simultan kembali sehingga didapatkan F_{hitung} sebesar 26,56 yang lebih besar dari $F_{0,05;12;23}$ sebesar 2,204 dan p -value sebesar $1,253 \times 10^{-10}$ yang lebih kecil dari taraf signifikansi 0,05 yang menunjukkan bahwa secara simultan seluruh parameter berpengaruh signifikan pada model. Kemudian dilakukan uji parsial dengan nilai $t_{0,025;23}$ sebesar 2,069.

Tabel 4: Uji parsial iterasi *backward elimination* kedua

Parameter	$ t_{hitung} $	p -value	Keputusan
β_0	10,089	$6,47 \times 10^{-10}$	H_0 ditolak
β_2	8,751	$8,89 \times 10^{-9}$	H_0 ditolak
β_4	8,869	$6,99 \times 10^{-9}$	H_0 ditolak
β_5	3,163	0,004347	H_0 ditolak
β_6	4,027	0,000526	H_0 ditolak
β_7	5,832	$6,08 \times 10^{-6}$	H_0 ditolak
β_8	6,971	$4,18 \times 10^{-7}$	H_0 ditolak
β_9	5,983	$4,22 \times 10^{-6}$	H_0 ditolak
β_{10}	6,459	$1,37 \times 10^{-6}$	H_0 ditolak
β_{11}	7,178	$2,61 \times 10^{-7}$	H_0 ditolak
β_{12}	8,096	$3,50 \times 10^{-8}$	H_0 ditolak
β_{13}	2,170	0,0406	H_0 ditolak
β_{14}	3,350	0,002777	H_0 ditolak

Berdasarkan Tabel 4, diketahui bahwa seluruh parameter berpengaruh signifikan parsial pada model maka dilanjutkan ke pengujian asumsi residual.

Pengujian normalitas residual menggunakan uji *Kolmogorov-Smirnov* mendapatkan p -value sebesar 0,688 lebih besar dari taraf signifikansi 0,05 yang berarti bahwa residual model TSR berdistribusi normal. Hasil pengujian independensi residual menggunakan uji *Ljung-Box* dapat dilihat pada gambar berikut



Gambar 4: Nilai *p-value* uji *Ljung-Box* model TSR dengan penambahan *lag*

Berdasarkan Gambar 4, nilai *p-value* semua *lag* berada di atas 0,05 yang berarti bahwa tidak terjadi otokorelasi pada residual model TSR. Semua parameter telah signifikan dan asumsi residual telah terpenuhi sehingga dapat dilanjutkan ke tahap selanjutnya yaitu prediksi dan peramalan. Adapun hasil peramalan dapat dilihat pada Tabel 5.


Tabel 5: Hasil peramalan model TSR

Periode	Peramalan
Januari 2023	1,984
Februari 2023	3,351
Maret 2023	8,154
April 2023	8,699
Mei 2023	5,509
Juni 2023	3,953
Juli 2023	4,326
Agustus 2023	5,433
September 2023	5,242
Oktober 2023	3,706
November 2023	2,956
Desember 2023	1,845

Kemudian dihitung akurasi peramalannya menggunakan MAPE

$$MAPE = \frac{1}{36} \sum_{t=25}^{60} \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100\% = 8,654\% \quad (15)$$

MAPE sebesar 8,654% berarti bahwa model TSR memiliki akurasi peramalan yang sangat baik.



Gambar 5: Grafik prediksi dan peramalan model TSR

Berdasarkan Gambar 5, terlihat bahwa hasil prediksi menggunakan model TSR dimulai dari periode $t = 25$ yaitu Bulan Januari 2020 karena pada pemodelannya menambahkan Z_{t-24} . Hasil prediksi mampu mengikuti pola dari data aktual di mana Produksi padi mengalami kenaikan di Bulan Februari hingga mengalami puncak produksi pada bulan Maret atau April. Hasil peramalan untuk Tahun 2023 mengikuti pola musiman pada tahun-tahun sebelumnya dengan puncak produksi diramalkan terjadi pada Bulan April 2023 dengan jumlah produksi sebesar 8,699 juta ton.

5. Conclusion

Peramalan produksi padi Tahun 2023 mengikuti pola musiman tahun-tahun sebelumnya yaitu mengalami kenaikan dari Bulan Januari hingga mengalami puncak produksi padi di Bulan April 2023 dengan jumlah sebesar 8,699 juta ton. Kemudian mengalami penurunan secara perlahan hingga Bulan Desember. Peramalan menggunakan model *time series regression* terhadap jumlah produksi padi di Indonesia mampu menghasilkan peramalan dengan akurasi *mean absolute percentage error* (MAPE) sebesar 8,654% yang menunjukkan peramalan yang sangat baik.

References

- Andronov, I. L. (2020). Advanced Time Series Analysis of Generally Irregularly Spaced Signals: Beyond the Oversimplified Methods. Dalam *Knowledge Discovery in Big Data from Astronomy and Earth Observation* (hlm. 191–224). Elsevier. <https://doi.org/10.1016/B978-0-12-819154-5.00022-9>
- Arumsari, M., & Dani, A. T. (2021). Peramalan Data Runtun Waktu menggunakan Model Hybrid Time Series Regression – Autoregressive Integrated Moving Average. *Jurnal Siger Matematika*, 2(1), 1–12. <https://doi.org/10.23960/jsm.v2i1.2736>
- Dani, A. T., Fauziyah, M., & Sandariria, H. (2023). Forecasting The Search Trends of The Keyword “Sarung Wadimor” In Indonesia on Google Trends Data Using Time Series Regression with Calender Variation and Arima Box-Jenkins. *Jurnal Matematika, Statistika dan Komputasi*, 19(3), 447–459. <https://doi.org/10.20956/j.v19i3.24551>
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice* (2 ed.). Otexts. https://books.google.co.id/books?id=_bBhDwAAQBAJ&printsec=copyright&redir_esc=y#v=onepage&q&f=false
- Jamila, A. U., Siregar, B. M., & Yunis, R. (2021). Analisis Runtun Waktu Untuk Memprediksi Jumlah Mahasiswa Baru Dengan Model Arima. *Paradigma - Jurnal Komputer dan Informatika*, 23(1). <https://doi.org/10.31294/p.v23i1.9758>
- Khair, U., Fahmi, H., Hakim, S. Al, & Rahim, R. (2017). Forecasting Error Calculation with Mean Absolute Deviation and Mean Absolute Percentage Error. *Journal of Physics: Conference Series*, 930(1). <https://doi.org/10.1088/1742-6596/930/1/012002>
- Makarti, P. P., & Karim, A. (2017). Perbandingan Metode Ordinary Least Square (OLS) dan Metode Regresi Robust Pada Hasil Produksi Padi di Kabupaten Indramayu. *Seminar Nasional Pendidikan, Sains dan Teknologi Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Muhammadiyah Semarang, October 2017*, 219–223. <https://jurnal.unimus.ac.id/index.php/psn12012010/article/view/3014>
- Makridakis, S. G., Wheelwright, S. C., & Hyndman, R. J. (1997). *Forecasting: Methods and Applications* (3 ed.). Wiley.
- Maulidina, F., Rustam, Z., Hartini, S., Wibowo, V. V. P., Wirasati, I., & Sadewo, W. (2021). Feature optimization using Backward Elimination and Support Vector Machines (SVM) algorithm for diabetes classification. *Journal of Physics: Conference Series*, 1821(1). <https://doi.org/10.1088/1742-6596/1821/1/012006>
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2008). *Introduction to Time Series Analysis and Forecasting*. John Wiley & Sons.
- Suhartono, Hisyam Lee, M., & Aishah Hamzah, N. (2010). Calendar variation model based on Time Series Regression for sales forecasts: The Ramadhan effects. *Proceedings of the Regional Conference on Statistical Sciences 2010*, 30–41. <https://api.semanticscholar.org/CorpusID:130612776>
- Surmaini, E., & Syahbuddin, H. (2016). Kriteria Awal Musim Tanam: Tinjauan Prediksi Waktu Tanam Padi Di Indonesia. *Jurnal Penelitian dan Pengembangan Pertanian*, 35(2), 47. <https://doi.org/10.21082/jp3.v35n2.2016.p47-56>
- Suwarno. (2010). Meningkatkan Produksi Padi Menuju Ketahanan Pangan yang Lestari. *Jurnal Pangan*, 19(3), 233–243. <https://www.jurnalpangan.com/index.php/pangan/article/view/150>

Wirdyacharya, B. S., & Prastuti, M. (2022). Peramalan Permintaan Semen di PT. XYZ Menggunakan Time Series Regression dan ARIMA. *Jurnal Sains dan Seni ITS*, 11(1).
<https://doi.org/10.12962/j23373520.v11i1.63222>