

## A Comparison of the Holt-Winters Additive and Multiplicative Methods with Grid search Optimization in Forecasting Red Chili Prices in Bengkulu City

### Perbandingan Metode *Holt-Winters Additive* dan *Multiplicative* dengan Optimasi *Grid search* dalam Peramalan Harga Cabai Merah di Kota Bengkulu

Ressy Fitrizka Haryanti<sup>1</sup>, Jose Rizal<sup>2\*</sup>, Winalia Agwil<sup>3</sup>, Idhia Sriliana<sup>4</sup>, Pepi Novianti<sup>5</sup>

<sup>1,2,3,4,5</sup> Statistics Study Program, Department of Mathematics, Faculty of Mathematics and Natural Sciences, University of Bengkulu, Indonesia

**Email:** <sup>1</sup>ressyfitrizkaharyanti2703@gmail.com, <sup>2</sup>jrizal04@unib.ac.id, <sup>3</sup>winaliaagwil@unib.ac.id, <sup>4</sup>idhiasriliana@unib.ac.id, <sup>5</sup>pie\_novianti@unib.ac.id

\* Corresponding Author

#### Abstract

The Holt-Winters Additive and Multiplicative methods are time series forecasting techniques that consider trend and seasonal patterns. To improve forecasting accuracy, optimization of model parameters, such as alpha, beta, and gamma, is required. This study compares four parameter optimization methods, namely Grid search, Bayesian optimization, Trial and error, and Nelder-mead, through simulation on the generation data and application on weekly red chili price data in Bengkulu City. Red chili was chosen as the object of study because it is a strategic horticultural commodity that has high demand and significant price fluctuations, thus affecting inflation and deflation in Bengkulu City. Simulation results show that the Grid search method consistently produces lower error values and more efficient computation time at iterations 15, 25, 50, and 100. Based on the optimal parameters of Grid search ( $\alpha = 1$ ,  $\beta = 0.1$ ,  $\gamma = 0.1$ ), a Holt-Winters model is obtained that can be used to forecast the price of red chili in Bengkulu City in the first 3 months of 2025. Based on the evaluation of the prediction results, the Additive model provides better performance than the Multiplicative model, with a MAPE value of 11,92% and an RMSE of 7450,52. These findings indicate that the combination of the Holt-Winters Additive method and Grid search optimization is effective in forecasting weekly red chili pepper prices, and can be used as a basis for policy making to control the price of strategic commodities in Bengkulu City.

**Keywords:** Holt-Winters, Grid search, Red Chili.

#### Abstrak



# JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Ressy Fitrizka Haryanti , Jose Rizal , Winalia Agwil, Idhia Sriliana, Pepi Novianti

Metode *Holt-Winters Additive* dan *Multiplicative* merupakan teknik peramalan deret waktu yang mempertimbangkan pola tren dan musiman. Untuk meningkatkan akurasi peramalan, diperlukan optimasi terhadap parameter model, seperti  $\alpha$ ,  $\beta$ , dan  $\gamma$ . Penelitian ini membandingkan empat metode optimasi parameter, yaitu *Grid search*, *Bayesian optimization*, *Trial and error*, dan *Nelder-mead*, melalui simulasi pada data bangkitan serta penerapan pada data harga cabai merah mingguan di Kota Bengkulu. Cabai merah dipilih sebagai objek kajian karena merupakan komoditas hortikultura strategis yang memiliki permintaan tinggi dan fluktuasi harga signifikan, sehingga berpengaruh terhadap inflasi dan deflasi di Kota Bengkulu. Hasil simulasi menunjukkan bahwa metode *Grid search* secara konsisten menghasilkan nilai error yang lebih rendah serta waktu komputasi yang lebih efisien pada iterasi 15, 25, 50, dan 100. Berdasarkan parameter optimal dari *Grid search* ( $\alpha = 1$ ,  $\beta = 0,1$ ,  $\gamma = 0,1$ ), diperoleh model *Holt-Winters* yang dapat digunakan untuk melakukan peramalan harga cabai merah di Kota Bengkulu pada 3 bulan pertama di tahun 2025. Berdasarkan evaluasi pada hasil prediksi, model *Additive* memberikan kinerja yang lebih baik dibandingkan model *Multiplicative*, dengan nilai MAPE sebesar 11,92% dan RMSE sebesar 7.450,52. Temuan ini menunjukkan bahwa kombinasi antara metode *Holt-Winters Additive* dan optimasi *Grid search* efektif digunakan untuk meramalkan harga cabai merah mingguan, serta dapat dijadikan sebagai dasar pengambilan kebijakan pengendalian harga komoditas strategis di Kota Bengkulu.

**Kata kunci:** *Holt-Winters*, *Grid search*, Cabai Merah.

## 1. PENDAHULUAN

Data deret waktu merupakan sekumpulan pengamatan yang dicatat secara teratur dalam urutan kronologis, dengan interval waktu yang konsisten seperti harian, mingguan, atau bulanan. Data ini dapat bersifat univariat maupun multivariat, dan umumnya menunjukkan pola seperti tren jangka panjang, musiman, serta fluktuasi acak. Peramalan deret waktu bertujuan untuk memprediksi nilai variabel pada periode mendatang berdasarkan pola historis yang telah diamati [7]. Salah satu metode peramalan yang banyak digunakan untuk data yang mengandung unsur musiman dan tren adalah metode *Holt-Winters*. Metode ini memiliki dua varian utama, yaitu *Additive* dan *Multiplicative*, yang masing-masing disesuaikan dengan jenis pola musiman dalam data. Keakuratan metode ini sangat bergantung pada pemilihan parameter pemulusan yang tepat, yaitu  $\alpha$  ( $\alpha$ ),  $\beta$  ( $\beta$ ), dan  $\gamma$  ( $\gamma$ ) [3]. Oleh karena itu, dibutuhkan pendekatan optimasi untuk menentukan kombinasi parameter yang optimal. Salah satu pendekatan yang dapat digunakan adalah *Grid search*, yaitu teknik pencarian sistematis dalam ruang parameter yang telah ditentukan berdasarkan batas atas dan batas bawah tertentu, guna meminimalkan nilai kesalahan peramalan [9]. Metode ini memungkinkan peningkatan akurasi model dengan mengevaluasi seluruh kombinasi parameter dalam batas tertentu.

Berbagai studi telah menunjukkan efektivitas metode *Holt-Winters* dalam peramalan deret waktu, misalnya Safitri, Dwidayati, dan Sugiman membandingkan metode *Holt-Winters* dengan ARIMA dalam memprediksi jumlah kunjungan wisatawan mancanegara dan diperoleh kesimpulan bahwa *Holt-Winters* menghasilkan peramalan yang lebih akurat dengan MAPE di bawah 10% [17]. Hal serupa juga ditemukan oleh Dewi dan Listiowarni dalam peramalan harga bahan pangan, yang menunjukkan bahwa metode *Holt-Winters* mampu menghasilkan estimasi yang sangat baik [3]. Berdasarkan penelitian sebelumnya, penelitian ini akan melakukan peramalan menggunakan metode *Holt-Winters* terhadap data cabai merah mingguan di Kota Bengkulu. Provinsi Bengkulu tercatat memiliki surplus produksi cabai merah sebesar 244,74%, tertinggi di wilayah Sumatera bagian Selatan, sekaligus memiliki konsumsi per kapita tertinggi, yaitu 0,58 kg per bulan. Selain itu, harga cabai merah mengalami ketidakstabilan yang signifikan dan memberi andil besar terhadap inflasi dan deflasi. Pada November 2024, cabai merah menyumbang deflasi sebesar -0,02% secara *month-to-*

month, sementara pada April 2024 menjadi komoditas penyumbang inflasi *year-on-year* sebesar 0,14%. Fluktuasi atau harga pangan yang tinggi dan tidak stabil dapat berdampak besar bagi produsen, ritel, dan konsumen. Selain itu, fluktuasi harga pangan dapat mengganggu perencanaan rantai pasokan dan keputusan investasi, yang mengakibatkan inefisiensi, pemborosan, dan menurunnya daya saing di sektor pertanian dan pangan [12]. Oleh karena itu, diperlukan metode peramalan yang akurat untuk mengantisipasi perubahan harga. Penelitian ini bertujuan meramalkan harga cabai merah mingguan di Kota Bengkulu menggunakan *Holt-Winters Additive* dan *Multiplicative* dengan optimasi *Grid search*. Secara khusus, penelitian ini bertujuan untuk: (1) membandingkan efektivitas dan efisiensi metode *Grid search* dengan metode lain seperti *Bayesian optimization*, *Trial and error*, dan *Nelder-mead* dalam mengestimasi parameter model melalui simulasi data bangkitan; (2) menghasilkan estimasi parameter terbaik untuk model *Holt-Winters Additive* dan *Multiplicative* dengan optimasi *Grid search*; dan (3) menghasilkan peramalan harga cabai merah mingguan untuk mendukung pengambilan keputusan di Kota Bengkulu.

## 2. MODEL STATISTIKA YANG DIGUNAKAN

### 2.1 Dekomposisi Data

Dekomposisi adalah teknik untuk memisahkan dan menyederhanakan struktur data menjadi komponen tren, musiman, dan residual agar lebih mudah dianalisis dan diinterpretasikan. Dalam proses dekomposisi data, dapat diasumsikan bahwa hubungan antar komponen memiliki struktur tertentu, yang diklasifikasikan ke dalam dua bentuk, yaitu struktur *Additive* dan *Multiplicative*. Secara matematis, model dekomposisi *Additive* dinyatakan sebagai berikut [3]:

$$y_t = M_t + T_t + R_t. \quad (2.1)$$

Sedangkan model dekomposisi *Multiplicative* diformulasikan sebagai berikut:

$$y_t = M_t \times T_t \times R_t. \quad (2.2)$$

Dimana  $y_t$  merupakan data aktual periode  $t$ ,  $M_t$  adalah komponen musiman pada periode  $t$ ,  $T_t$  merupakan komponen tren pada periode  $t$ , dan  $R_t$  adalah residual pada periode  $t$

Model dekomposisi *aditif* cocok digunakan jika fluktuasi musiman stabil dan tidak tergantung pada level data. Sebaliknya, model multiplikatif lebih sesuai jika variasi berubah seiring perubahan level data. Berikut merupakan Langkah-langkah dalam metode dekomposisi klasik. Dimulai dengan menghitung komponen tren dengan menggunakan teknik rata-rata bergerak untuk menghitung komponen tren dari data asli. Setelah itu, hilangkan tren dari data dengan melakukan pengurangan (model *Additive*) dan pembagian (model *Multiplicative*) antara data asli dan komponen tren. Hasil dari proses ini disebut data yang sudah *detrended* (telah dihilangkan trennya). Selanjutnya, hitung komponen musiman dengan mengelompokkan data *detrended* berdasarkan periode musiman, setelah itu hitung rata-rata dari data *detrended* untuk setiap periode musiman. Pada model *Additive*, nilai musiman diperoleh dari selisih antara rata-rata tiap musim dan rata-rata keseluruhan. Pada model *Multiplicative*, nilai musiman dihitung dengan membagi rata-rata tiap musim dengan rata-rata total. Setelah komponen tren dan musiman diketahui, hitung sisa data yang tidak dijelaskan oleh keduanya (residual) dengan rumus berikut:

$$\text{Additive:} \quad R_t = y_t - M_t - T_t$$

$$\text{Multiplicative:} \quad R_t = \frac{y_t}{M_t \cdot T_t}.$$

Setelah komponen semua komponen diperoleh, lakukan analisis arah tren, identifikasi pola musiman, serta evaluasi residual untuk memastikan nilainya bersifat acak dan tidak menunjukkan pola tertentu.

### 2.2 Identifikasi Pola Tren dan Musiman

Identifikasi pola tren dan musiman merupakan tahap awal yang krusial dalam analisis deret waktu, khususnya sebelum penerapan model *Holt-Winters*. Pola tren diidentifikasi menggunakan uji statistik Mann-Kendall [13], yang mampu mendeteksi kecenderungan naik atau turun secara signifikan dalam data. Sementara itu, pola musiman dianalisis melalui pendekatan periodogram [19], yang memberikan informasi mengenai keberadaan dan periode komponen musiman berdasarkan frekuensi dominan dalam deret waktu.

### 2.2.1 Uji Mann-Kendall

Uji Mann-Kendall adalah salah satu metode non-parametrik untuk mengidentifikasi tren dengan hipotesis  $H_0$ : Tidak terdapat tren dalam deret waktu dan  $H_1$ : Terdapat tren dalam deret waktu. Statistik uji dihitung menggunakan rumus berikut [13]:

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(y_j - y_i), \quad (2.3)$$

dimana:

$$\text{sgn}(y_j - y_i) = \begin{cases} +1, & y_j - y_i > 0 \\ 0, & y_j - y_i = 0 \\ -1, & y_j - y_i < 0. \end{cases}$$

Variabel  $n$  menyatakan jumlah observasi dalam data deret waktu, sedangkan variabel  $y_j$  dan  $y_i$  merupakan nilai observasi pada waktu ke- $j$  dan ke- $i$ . Setelah nilai statistik  $S$  pada Persamaan (2.3) dihitung, maka, langkah selanjutnya adalah menghitung nilai statistik  $Z$ . Jika  $n > 10$ , maka distribusi  $S$  dapat didekati dengan distribusi normal [13], sehingga uji signifikansi dapat dilakukan menggunakan statistik  $Z$  menggunakan Persamaan (2.4) berikut:

$$Z_{hitung} = \begin{cases} \frac{S - 1}{\sqrt{\text{Var}(S)}}, & S > 0 \\ 0, & S = 0 \\ \frac{S + 1}{\sqrt{\text{Var}(S)}}, & S < 0 \end{cases} \quad (2.4)$$

Jika nilai  $|Z_{hitung}| > Z_{(tabel) \alpha/2}$  atau  $p_{value}(|Z_{hitung}|) < 0,05$ , maka  $H_0$  ditolak, sehingga dapat disimpulkan bahwa terdapat tren pada data deret waktu. Sebaliknya, jika nilai  $|Z_{hitung}| < Z_{(tabel) \alpha/2}$  atau  $p_{value}(|Z_{hitung}|) > 0,05$ , maka gagal tolak  $H_0$ , sehingga dapat disimpulkan bahwa tidak terdapat tren pada suatu data deret waktu. Selain itu, berdasarkan nilai  $S$  juga dapat disimpulkan apakah tren baik atau turun. Jika nilai  $S > 0$ , maka terdapat tren naik pada data. Jika  $S < 0$ , maka dapat disimpulkan bahwa terdapat tren turun, sedangkan, jika  $S = 0$ , maka tidak terdapat tren naik atau turun yang mengindikasikan tidak terdapat pola tren.

### 2.2.2 Periodogram

Periodogram adalah alat yang digunakan untuk melihat seberapa kuat suatu pola berulang (musiman) muncul dalam data berdasarkan frekuensinya. Penelitian Darmawan, Mulyani, dan Sudartianto (2012) menyusun langkah-langkah uji periodogram [19] dengan merepresentasikan data dalam bentuk deret fourier berikut:

$$Z_t = \sum_{k=0}^{[n/2]} (a_k \cos \omega_k t + b_k \sin \omega_k t), \quad (2.5)$$

dimana  $\omega_k$  merupakan frekuensi fourier yang dihitung dengan  $\omega_k = 2\pi \cdot k/n$ .

Dengan  $k = 0, 1, \dots, [n/2]$  adalah komponen frekuensi dari  $\omega_k$ . Setelah itu, hitung koefisien fourier  $a_k$  dan  $b_k$  menggunakan Persamaan (2.6):

$$a_k = \begin{cases} \frac{1}{n} \sum_{t=1}^n Z_t \cos \omega_k t, & k = 0 \text{ dan } k = \frac{n}{2} \text{ jika } n \text{ genap} \\ \frac{2}{n} \sum_{t=1}^n Z_t \cos \omega_k t, & k = 1, 2, \dots, \frac{(n-1)}{2} \end{cases} \quad (2.6)$$

$$b_k = \frac{2}{n} \sum_{t=1}^n Z_t \sin \omega_k t, \quad k = 1, 2, \dots, \frac{(n-1)}{2}$$

Selanjutnya, hitung ordinat periodogram menggunakan Persamaan (2.7) dibawah ini:

$$I(\omega_k) = \begin{cases} na_0^2, & k = 0 \\ \frac{n}{2}(a_k^2 + b_k^2), & k = 1, 2, \dots, \frac{(n-1)}{2} \\ na_k^2, & k = \frac{n}{2} \text{ ketika } n \text{ genap} \end{cases} \quad (2.7)$$

Setelah diperoleh ordinat periodogram, selanjutnya uji pengaruh musiman masing-masing frekuensi fourier dengan hipotesis uji T-hitung, dimana  $H_0: \alpha = \beta = 0$  (Tidak terdapat pola musiman) dan  $H_1: \alpha \neq 0$  atau  $\beta \neq 0$  (Terdapat pola musiman). Selanjutnya hitung statistik uji menggunakan Persamaan (2.8) berikut:

$$T = \frac{I^{(1)}(\omega_{(1)})}{\sum_{k=1}^{[n/2]} I(\omega_{(k)})} \quad (2.8)$$

dimana:

$I^{(1)}(\omega_{(1)})$  :  $\max\{I(\omega_{(k)})\}$ .

$I^{(1)}(\omega_{(1)})$  : ordinat maksimum dari periodogram pada frekuensi fourier

$I(\omega_{(k)})$  : nilai ordinat periodogram pada frekuensi fourier ke-k

**Tabel 2.1.** Nilai kritis  $g_a$  dengan  $a = 0,05$

| N  | $g_a$ (by extract formula) | $g_a$ (by first term only) | N  | $g_a$ (by extract formula) | $g_a$ (by first term only) |
|----|----------------------------|----------------------------|----|----------------------------|----------------------------|
| 5  | 0,68377                    | 0,68377                    | 30 | 0,19784                    | 0,19794                    |
| 10 | 0,44495                    | 0,44495                    | 35 | 0,17513                    | 0,17525                    |
| 15 | 0,33462                    | 0,33643                    | 40 | 0,15738                    | 0,15752                    |
| 20 | 0,2704                     | 0,27046                    | 45 | 0,1431                     | 0,14324                    |
| 25 | 0,22805                    | 0,22813                    | 50 | 0,13135                    | 0,13149                    |

$N = \frac{(n-1)}{2}$ , jika  $n$  ganjil dan  $N = (n/2) - 1$  jika  $n$  genap

Jika nilai  $T > g_a$ , maka tolak  $H_0$ , artinya terdapat pola musiman pada data. Sebaliknya, jika nilai  $T < g_a$ , maka gagal tolak  $H_0$ , artinya tidak terdapat pola musiman pada data.

1. Melakukan pemotongan data untuk melihat perubahan pola data

### 2.3 Metode Holt-Winters

*Holt-Winters* adalah metode peramalan *exponential smoothing* yang dikembangkan oleh Peter Winters pada tahun 1960, dengan menambahkan persamaan musiman pada metode Holt yang telah ada sebelumnya, yaitu pada tahun 1957 [2]. Metode *Holt-Winters* merupakan salah satu model prediksi yang paling sederhana namun kuat. Metode ini menggunakan perhitungan peramalan dasar, sehingga tidak membutuhkan sumber daya yang canggih dan waktu operasi yang lama. Metode ini digunakan untuk menangkap pola musiman data dengan tingkat akurasi yang tinggi, dengan mempertimbangkan tren dan musiman pada data [18], oleh karena itu, metode ini dianggap relevan untuk menghasilkan peramalan pada data harga cabai merah yang di asumsikan memiliki pola *trend*

dan musiman. Ketika data memperlihatkan adanya unsur *trend* dan perilaku musiman maka Metode *Holt-Winters* dapat digunakan. Inilah yang menjadi kelebihan atau keunggulan dari Metode *Holt-Winters* yaitu dapat mengatasi pola *trend* dan musiman yang muncul secara bersamaan [6]. Hal ini menunjukkan bahwa Metode *Holt-Winters* tidak mengharuskan data yang digunakan bersifat stasioner dan bisa digunakan pada data yang tidak bersifat stasioner [5].

Terdapat tiga pemulusan yang menjadi dasar dari Metode *Holt-Winters*, yaitu pemulusan *level*, pemulusan *trend*, dan pemulusan musiman [2]. Metode ini memiliki dua bentuk yaitu model *additive* dan *multiplicative*. Model *additive* mengasumsikan bahwa fluktuasi musiman bersifat konstan dan tidak bergantung pada level data, sedangkan model *multiplicative* mengasumsikan bahwa musiman berubah secara proporsional dengan level data [4].

#### 1. *Holt-Winters Additive*

Pada metode ini diperlukan proses inisialisasi yaitu penentuan nilai awal dari suatu estimasi. Rumus untuk menentukan nilai awal pada pemulusan *level* adalah sebagai berikut:

$$S_s = \frac{1}{s}(y_1 + y_2 + \dots + y_s). \quad (2.9)$$

Berikut rumus penentuan nilai awal pemulusan *trend*:

$$b_s = \frac{1}{s} \left( \frac{y_{s+1} - y_1}{s} + \frac{y_{s+2} - y_2}{s} + \dots + \frac{y_{s+s} - y_s}{s} \right). \quad (2.10)$$

Berikut rumus penentuan nilai awal pada pemulusan musiman:

$$l_s = (y_s - S_s). \quad (2.11)$$

Variabel  $S_s$  menyatakan nilai awal pemulusan *level*. Sedangkan, variabel  $b_s$  menyatakan nilai awal pemulusan *trend*. Variabel  $l_s$  adalah nilai awal pemulusan pola musiman, sedangkan  $s$  merupakan panjang musiman dalam satu periode musim. Variabel  $y_s$  merupakan nilai aktual pada deret  $t$  dalam satu periode  $s$ , sedangkan variabel  $y_{s+s}$  menyatakan nilai aktual pada deret  $t$  dalam dua periode  $s$

Rumus pemulusan *Holt-Winters Additive* adalah sebagai berikut [25]:

- a. Rumus pemulusan *level* dinyatakan dibawah ini:

$$S_t = \alpha(y_t - l_{t-s}) + (1 - \alpha)(S_{t-1} + b_{t-1}). \quad (2.12)$$

Dimana  $S_t$  merupakan nilai *level* pada deret  $t$ ,  $l_{t-s}$  merupakan estimasi nilai musiman deret  $t$  pada periode  $s$ , sedangkan  $S_{t-1}$  adalah estimasi nilai *level* deret  $t$  pada periode  $s$ , dan  $b_{t-1}$  merupakan estimasi nilai tren deret  $t$  pada periode  $s$ .

- b. Rumus pemulusan *trend* dinyatakan sebagai berikut:

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1}. \quad (2.13)$$

Dengan  $b_t$  adalah nilai tren pada deret  $t$ .

- c. Rumus pemulusan musiman dinyatakan sebagai berikut:

$$I_t = \gamma(y_t - S_t) + (1 - \gamma)l_{t-s}. \quad (2.14)$$

$I_t$  merupakan nilai musiman pada deret  $t$

- d. Rumus peramalan dinyatakan sebagai berikut:

$$F_{t+m} = S_t + b_t m + I_{t-s+m}. \quad (2.15)$$

$F_{t+m}$  : Menunjukkan peramalan pada waktu  $t + m$

Variabel  $m$  menyatakan banyaknya deret ke depan yang akan diramalkan dan  $I_{t-s+m}$  adalah Estimasi nilai musiman deret  $t-s+m$ .

#### 2. *Holt-Winters Multiplicative*

Rumus pemulusan Metode *Holt-Winters Multiplicative*, yaitu sebagai berikut:

- a. Pemulusan *level*

$$S_t = a \frac{y_t}{I_{t-s}} + (1 - a)(S_{t-1} + b_{t-1}), \quad (2.16)$$

- b. Pemulusan *trend*

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1}, \quad (2.17)$$

- c. Pemulusan musiman

$$I_t = \gamma \frac{y_t}{S_t} + (1 - \gamma)I_{t-s}, \quad (2.18)$$

d. Rumus peramalan dinyatakan sebagai berikut:

$$F_{t+m} = (S_t + b_t m) I_{t-s+m}. \quad (2.19)$$

dengan  $0 \leq \alpha, \beta, \gamma \leq 1$ .

Dalam pemulusan *exponential*, nilai awal sangat diperlukan, karena belum tersedianya peramalan untuk  $t - 1$ , sehingga nilai ramalan  $S_{t-1}$  belum ada. Menurut metode pemulusan *exponential Holt-Winters*, nilai awal dapat ditentukan sembarang berdasarkan nilai yang telah ditetapkan, yaitu [1]:

$$S_{s-1} = y_{s-1}.$$

Rumus lain yang dapat digunakan dalam penentuan nilai awal adalah:

$$S_s = \frac{1}{s} (y_1 + y_2 + \dots + y_s). \quad (2.20)$$

$$b_s = \frac{1}{s} \left( \frac{(y_{s+1} - y_1)}{s} + \frac{(y_{s+2} - y_2)}{s} + \dots + \frac{(y_{s+s} - y_s)}{s} \right). \quad (2.21)$$

$$I_s = \frac{y_s}{S_s}. \quad (2.22)$$

Dimana  $s = 1, 2, 3, \dots, S$ .

## 2.4 Optimasi Parameter

Berikut adalah parameter yang dibutuhkan pada proses pemulusan Metode *Holt-Winters* [20]:

1.  $\alpha$ : parameter *smoothing level* untuk menyesuaikan besar bobot diberikan pada data terbaru.
2.  $\beta$ : parameter *smoothing trend* yang digunakan untuk menangani komponen *trend* dalam data.
3.  $\gamma$ : parameter *smoothing musiman* digunakan untuk menangani fluktuasi musiman dalam data.

Ketiga parameter ini berkisaran antara 0 dan 1. Optimasi ketiga parameter ini dapat dilakukan dengan menggunakan berbagai metode, seperti yang disebutkan dalam penelitian ini, yaitu:

### a. Grid search

*Grid search* bekerja dengan melakukan pencarian berdasarkan jumlah angka secara menyeluruh terhadap subset ruang *hyperparameter*, dimana pada ruang subset terdapat nilai minimal (batas bawah) dan nilai maksimal (batas atas). Algoritma ini akan menentukan nilai *hyperparameter* optimal dengan cara membagi ruang pencarian *hyperparameter* kedalam bentuk *grid* dan mengevaluasi seluruh kemungkinan yang ada [24]. Tahapan optimasi menggunakan *Grid search* dimulai dengan menentukan parameter yang akan dioptimasi (misalnya  $\alpha, \beta, \gamma$ ). Selanjutnya, tentukan ruang pencarian parameter, terdapat dua tahapan pencarian *Grid Search* yaitu:

- a. *Loose grid*: pencarian parameter dengan rentang yang lebih lebar (*increment* 0,1).
- b. *Finer grid*: pencarian parameter dengan rentang sempit di sekitaran nilai terbaik dari *loose grid*, (*increment* 0,01).

Setelah itu, bangun *grid* kombinasi parameter dan evaluasi kinerja model untuk semua kombinasi. Terakhir pilih kombinasi parameter terbaik dengan akurasi tertinggi atau *error* terendah [15].

### b. Bayesian Optimization

*Bayesian Optimization* adalah metode berbasis pendekatan probabilistik yang memodelkan ketidakpastian fungsi objektif, sehingga proses eksplorasi ruang parameter menjadi lebih efektif. Tahapan *Bayesian Optimization* dimulai dengan menentukan fungsi objektif berupa nilai *error* (misalnya SSE). Kedua, inisialisasi yaitu proses uji coba kombinasi awal parameter (misalnya  $\alpha, \beta, \gamma$ ) secara acak dan evaluasi menggunakan fungsi objektif yang dipilih. Setelah itu, gunakan hasil inisialisasi berupa nilai-nilai SSE terhadap kombinasi parameter yang telah di uji untuk melakukan *modelling* berupa model *probabilistic* yang umumnya menggunakan pendekatan *Gaussian* untuk memperkirakan titik kombinasi dengan SSE minimum berada. Selanjutnya, hitung fungsi akuisisi misalnya menggunakan *Expected Improvement* (EI) untuk menentukan titik pencarian. Evaluasi fungsi akuisisi menggunakan fungsi objektif berdasarkan titik pencarian. Lakukan pembaharuan model *probabilistic* dengan menggunakan data baru yang diperoleh dari evaluasi yang telah dilakukan dan ulangi Langkah 4 dan 5 hingga ditemukan parameter terbaik [8].

### c. *Nelder-Mead*

Metode ini dikembangkan oleh Nelder dan Mead pada tahun 1965 yang merupakan metode sederhana untuk mencari minimum lokal dari suatu fungsi yang memiliki sejumlah variabel. Metode *Nelder-Mead* membandingkan  $n + 1$  nilai fungsi pada  $n + 1$  titik sudut untuk suatu permasalahan berdimensi  $n$  [11]. Berikut ini merupakan tahapan optimasi *Nelder-Mead*. Pertama lakukan inisialisasi simplex yaitu proses pemilihan  $n + 1$  titik awal dalam ruang  $n$ -dimensi sebagai simplex awal, misal  $f(1), f(2), f(3)$ , di mana setiap titik berisi kombinasi parameter, contohnya:  $f(1) = f(\alpha = 1, \beta = 1, \gamma = 0, 1)$ . Kedua, evaluasi simplex awal menggunakan metrik evaluasi (misalnya SSE). Urutkan simplex dari titik terbaik hingga titik terburuk  $f(1) < f(2) < f(3)$ . Selanjutnya, hitung titik pusat atau centroid  $f(c)$  yang merupakan rata-rata dari semua titik kecuali titik terburuk  $f(3)$ . Lakukan proses refleksi dengan cara merefleksikan titik terburuk  $f(3)$  melalui centroid  $f(c)$  untuk mendapatkan titik refleksi atau  $f(r)$ . Berikut evaluasi  $f(r)$  menggunakan metrik evaluasi (misalnya: SSE): Jika  $f(r)$  memiliki nilai SSE diantara titik terbaik  $f(1)$  dan kedua terbaik  $f(2)$ , maka titik terburuk  $f(3)$  diganti dengan  $f(r)$ . Selanjutnya, jika  $f(r)$  memiliki nilai SSE lebih baik dari titik terbaik  $f(1)$ , maka lakukan proses ekspansi dari titik refleksi  $f(r)$  di sepanjang garis antara  $f(1)$  dan  $f(2)$  untuk mendapatkan titik ekspansi atau  $f(e)$ .

Untuk evaluasi  $f(e)$  dengan menggunakan metrik evaluasi (misalnya: SSE) sebagai berikut: Jika  $f(e)$  memiliki nilai SSE lebih baik dari  $f(r)$ , maka  $f(3)$  diganti dengan  $f(e)$ . Selanjutnya, jika  $f(e)$  memiliki nilai SSE lebih buruk dari  $f(r)$ , maka  $f(3)$  diganti dengan  $f(r)$ .

Jika proses refleksi dan ekspansi tidak terpenuhi, artinya titik refleksi  $f(r)$  memiliki nilai SSE yang lebih buruk dibandingkan  $f(2)$ . Selanjutnya, lakukan proses kontraksi terhadap titik terburuk  $f(3)$  menuju titik antara  $f(3)$  dan  $f(r)$  untuk mendapatkan titik  $f(k)$ . Dikarenakan sulit memperoleh titik minimum pada tahapan ini, biasanya proses kontraksi akan menghasilkan 2 titik kontraksi  $f(k1)$  dan  $f(k2)$ . Setelah itu, evaluasi titik kontraksi  $f(k)$  menggunakan metrik evaluasi (misalnya: SSE) sebagai berikut: Jika salah satu titik kontraksi memiliki nilai SSE yang lebih baik dari titik kedua terbaik ( $f(k1), f(k2)) < f(2)$ , Maka  $f(3)$  diganti dengan  $f(k1)$  atau  $f(k2)$ . Selanjutnya, jika proses refleksi, ekspansi, dan konstruksi gagal, lakukan penyusutan simplex menuju titik terbaik  $f(1)$ .

Langkah terakhir dalam algoritma *Nelder-Mead* adalah melakukan iterasi secara berulang hingga memenuhi salah satu kriteria penghentian. Proses iterasi dihentikan apabila terjadi perubahan nilai SSE yang sangat kecil antar iterasi, ukuran simplex menyusut hingga di bawah batas toleransi (mengindikasikan konvergensi), atau jumlah iterasi telah mencapai batas maksimum yang telah ditentukan [22].

### d. *Trial and Error*

*Trial and Error* dikembangkan oleh Edward Thorndike berlandaskan pada teori koneksionisme [21]. Metode *trial and error* mencerminkan proses yang berbasis pada pengalaman langsung. Meskipun dianggap sebagai pendekatan yang tidak terarah, metode ini justru melibatkan proses berpikir yang intens dan eksploratif. Serangkaian percobaan dan kesalahan yang dilakukan secara berulang memberikan umpan balik yang membantu menemukan solusi secara lebih tepat dan efisien [23]. Berikut adalah tahapan optimasi *Trial and Error*:

1. Tentukan parameter yang akan dioptimalkan (misalnya  $\alpha, \beta, \gamma$ ).
  2. Tentukan beberapa nilai parameter secara manual dan uji kombinasi nilai-nilai tersebut.
  3. Hitung metrik evaluasi (misalnya menggunakan SSE) dari setiap kombinasi.
- Pilih kombinasi dengan nilai *error* terendah sebagai kombinasi terbaik.

## 2.5 Evaluasi Model

### 1. MAPE (*Mean Absolute Percentage Error*)

MAPE merupakan pengujian yang dapat dilakukan untuk melihat ketepatan prediksi yang menggambarkan pengukuran ke dalam bentuk persentase. MAPE biasa ditujukan untuk menguji hasil

prediksi dikarenakan nilai MAPE lebih mudah untuk dipresentasikan. Semakin rendah nilai MAPE maka model peramalan yang dihasilkan semakin baik [10]. Nilai MAPE dapat diperoleh menggunakan Persamaan (2.24) berikut [15]:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - F_t}{y_t} \right| \times 100\%. \quad (2.23)$$

Berikut merupakan kriteria hasil evaluasi model menggunakan MAPE [16]:

**Tabel 2.2.** Tabel kriteria MAPE

| No | Nilai  | Keterangan   |
|----|--------|--------------|
| 1  | <10%   | Sangat bagus |
| 2  | 10-20% | Bagus        |
| 3  | 20-50% | Cukup        |
| 4  | >50%   | Buruk        |

## 2. RMSE (Root Mean Squared Error)

RMSE merupakan merupakan salah satu ukuran yang umum digunakan untuk mengevaluasi tingkat akurasi suatu model prediksi. RMSE dihitung berdasarkan akar dari rata-rata kuadrat selisih antara nilai aktual dengan nilai hasil prediksi. Semakin kecil nilai RMSE, maka semakin baik kualitas model dalam memprediksi data yang mendekati nilai sebenarnya. RMSE dapat dihitung menggunakan Persamaan (2.25) berikut [14]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - F_t)^2} \quad (2.24)$$


## 3. METODE PENELITIAN

### 3.1 Jenis dan Sumber Data

Data yang digunakan adalah data harga eceran cabai merah mingguan di Kota Bengkulu periode Januari 2023-Desember 2024, yang merupakan data kuantitatif dengan skala numerik. Periode ini dipilih karena mencakup dua siklus musiman dengan 104 observasi yang cukup untuk mengidentifikasi pola tren dan musiman menggunakan metode *Holt-Winters*. Pemilihan periode ini relevan untuk peramalan awal 2025 serta menghindari pola historis yang kurang representatif. Penelitian ini menggunakan data sekunder yang diperoleh dari situs *website* Sistem Informasi Layanan Statistik Badan Pusat Statistik (BPS) Indonesia.

### 3.2 Analisis Data

Berikut tahapan-tahapan yang dilakukan dalam analisis data pada penelitian ini:



**Gambar 3.1.** Diagram alir penelitian

## 4. HASIL DAN PEMBAHASAN

### 4.1 Statistik Deskriptif


Statistik deskriptif digunakan untuk menggambarkan karakteristik data awal. Tabel berikut merangkum data harga eceran cabai merah di Kota Bengkulu sebagai dasar analisis lanjutan.

**Tabel 4.1.** Ringkasan Data

| <i>min</i> | <i>1st Qu</i> | <i>median</i> | <i>Mean</i> | <i>3rd Qu</i> | <i>Max</i> | <i>Skewness</i> | <i>Kurtosis</i> |
|------------|---------------|---------------|-------------|---------------|------------|-----------------|-----------------|
| 20.927     | 28.030        | 30.758        | 35.780      | 41.557        | 79.144     | 1,412           | 5,123           |

Berdasarkan Tabel 4.1, harga eceran cabai merah terendah sebesar Rp20.927 dan harga tertinggi sebesar Rp79.144, dengan rata-rata harga sebesar Rp35.780. Nilai kuartil pertama ( $Q_1$ ) sebesar Rp28.030 menunjukkan bahwa 25% data harga berada di bawah nilai tersebut, sementara kuartil ketiga ( $Q_3$ ) sebesar Rp41.557 menunjukkan bahwa 75% data berada di bawah nilai tersebut dan 25% berada di atasnya. Rentang antarkuartil (*interquartile/IQR*) sebesar Rp13.527 mencerminkan sebaran harga yang terjadi di sekitar tengah-tengah distribusi. Kuartil pertama digunakan sebagai acuan harga murah dan kuartil ketiga sebagai ambang harga mahal.

Nilai *skewness* sebesar 1,412 menunjukkan distribusi positif condong ke kanan dan *kurtosis* sebesar 5,124 mengindikasikan distribusi *leptokurtic*, yaitu distribusi dengan puncak tajam dan ekor panjang, yang mengindikasikan adanya nilai-nilai ekstrem atau *outlier*. Meskipun demikian, tidak dilakukan penanganan terhadap *outlier*, karena metode *Holt-Winters* tidak memerlukan asumsi distribusi normal atau simetris. Selain itu, nilai-nilai ekstrem tersebut dianggap mencerminkan kondisi nyata yang relevan secara ekonomi. Oleh karena itu, data digunakan sebagaimana adanya, dan performa model dievaluasi menggunakan ukuran seperti MAPE dan RMSE. Selain itu, statistik deskriptif dari data dapat dilihat secara grafis sebagai berikut:




**Gambar 4.1.** Plot data penelitian

Berdasarkan Gambar 4.1, harga cabai merah mingguan menunjukkan fluktuasi yang cukup tajam selama tahun 2023 hingga 2024. Lonjakan harga signifikan terjadi pada awal tahun 2024, kemudian diikuti oleh penurunan secara bertahap. Grafik ini menunjukkan adanya komponen tren, yaitu kecenderungan harga meningkat pada akhir 2023 hingga awal 2024. Pola musiman juga tampak dari adanya lonjakan harga yang berulang pada awal tahun, sedangkan variasi harga yang tidak beraturan mengindikasikan adanya komponen acak yang kemungkinan dipengaruhi oleh faktor-faktor seperti cuaca, pasokan, atau dinamika permintaan di pasar lokal. Untuk mengidentifikasi pola data dengan lebih jelas, dapat dilakukan analisis dekomposisi pada data ini.


### 4.2 Dekomposisi Data

Dekomposisi data merupakan proses memecah data kompleks menjadi komponen-komponen utama, seperti tren, musiman dan acak, sehingga lebih mudah dipahami, dianalisis, atau dikelola. *Plot* dekomposisi terdiri dari empat bagian, yaitu *observed*, *trend*, *seasonal*, dan *random*. Berikut ini merupakan *plot* dekomposisi dari hasil eksplorasi awal pada data harga cabai merah mingguan di Kota Bengkulu untuk mengidentifikasi struktur pola dalam data.

**JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI**  
**Ressy Fitrizka Haryanti , Jose Rizal , Winalia Agwil, Idhia Sriliana, Pepi Novianti**



**Gambar 4.2.** Plot dekomposisi Additive



**Gambar 4.3.** Plot dekomposisi Multiplicative

Berdasarkan Gambar 4.2, terlihat tren harga cabai merah meningkat, dengan pola musiman berulang dari tahun ke tahun, terutama pada awal dan pertengahan tahun. Skala musiman berada antara -10.000 hingga +30.000, dan fluktuasinya relatif stabil meskipun tren meningkat tajam di awal 2024, menunjukkan ketidakbergantungan musiman terhadap tren. Nilai residual pada model aditif tampak konstan dan tidak acak. Sedangkan, pada Gambar 4.3 menunjukkan bahwa model multiplikatif mengikuti tren yang sama, dengan tren meningkat sejak pertengahan 2023 hingga awal 2024. Skala musiman berada antara 0,75 hingga 1,75, dan meskipun dalam bentuk rasio terhadap tren, fluktuasinya tetap stabil, menunjukkan tidak adanya proporsionalitas nyata dengan tren. Residual pada model ini juga konstan, sekitar 1,05.

Hasil dekomposisi menunjukkan pola musiman memiliki amplitudo stabil meskipun tren meningkat tajam, sehingga model *additive* lebih sesuai karena komponen musiman tidak bergantung pada tren. Selain analisis visual, identifikasi pola tren dapat dilakukan menggunakan uji Mann-Kendall. Berdasarkan Persamaan (2.2) dan (2.3), diperoleh hasil statistik uji berikut:

**Tabel 4.2.** Hasil Uji Mann-Kendall

| $Z_{hitung}$ | n   | $p_{value}$ | S    | Var S    | $\tau$   |
|--------------|-----|-------------|------|----------|----------|
| 4,8036       | 104 | 0,000001559 | 1711 | 126725,7 | 0,320323 |

Berdasarkan Tabel 4.2, diketahui nilai  $p_{value}(|Z_{hitung}|) < 0,05$ , maka  $H_0$  ditolak, artinya terdapat tren pada data. Selain itu, berdasarkan nilai S, dapat disimpulkan bahwa terdapat tren positif atau kenaikan dari waktu ke waktu.

Setelah memastikan bahwa terdapat pola tren pada data, selanjutnya identifikasi pola musiman menggunakan pengujian hipotesis periodogram. Berdasarkan Persamaan (2.8), diperoleh hasil statistik uji berikut:

**Tabel 4.3.** Hasil Analisis Periodogram

| Periode | $T$    | $g_a$   | Keterangan  |
|---------|--------|---------|-------------|
| Awal    | 0,9761 | 0,22805 | Tolak $H_0$ |
| Akhir   | 0,9195 | 0,22805 | Tolak $H_0$ |

Berdasarkan Tabel 4.3, diketahui nilai  $T$  untuk periode awal tahun pertama (minggu 1-52) sebesar  $0,9761 > g_a = 0,22805$  dan periode akhir tahun kedua (minggu 53-104) sebesar  $0,9195 > g_a = 0,22805$ , sehingga tolak  $H_0$ , artinya terdapat pola musiman pada data harga cabai merah baik pada periode awal maupun periode akhir.

**JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI**  
**Ressy Fitrizka Haryanti , Jose Rizal , Winalia Agwil, Idhia Sriliana, Pepi Novianti**

Berdasarkan identifikasi pola data dengan menggunakan Mann-Kendal dan Periodogram, diketahui bahwa terdapat pola tren dan musiman pada data harga cabai merah. Oleh karena itu, dapat disimpulkan bahwa data harga cabai merah mingguan di Kota Bengkulu memenuhi asumsi untuk pemodelan *Holt-Winters* yang digunakan untuk data yang memiliki pola tren dan musiman.

#### 4.3 Simulasi Optimasi Parameter

Pada proses simulasi ini, tahapan pertama yang harus dilakukan adalah menentukan nilai parameter awal yang akan digunakan untuk membangkitkan data dengan kriteria *Holt-Winters* yang memiliki pola *trend*, musiman, dan pola acak. Berikut ini merupakan parameter awal yang ditetapkan untuk proses simulasi:

**Tabel 4.4.** Parameter awal *Holt-Winters*

| $\alpha$ (Alpha) | $\beta$ (Beta) | $\gamma$ (Gamma) |
|------------------|----------------|------------------|
| 1                | 0,2            | 0,1              |

Simulasi ini dilakukan untuk optimasi parameter *Holt-Winters* menggunakan *Grid search*, *Bayesian Optimization*, *Trial and Error*, dan *Nelder-Mead*. Kinerja dari setiap metode optimasi dinilai berdasarkan SSE, RMSE, dan MAPE. Berikut ini merupakan perbandingan rata-rata SSE, RMSE, dan MAPE dari setiap metode optimasi:

**Tabel 4.5.** Perbandingan rata-rata SSE, RMSE, dan MAPE

| iterasi | metode                       | Rata-Rata      |                |                |                |
|---------|------------------------------|----------------|----------------|----------------|----------------|
|         |                              | SSE            | RMSE           | MAPE           | Time           |
| 15      | <i>Grid search</i>           | <b>36,7381</b> | <b>0,62967</b> | <b>2,54134</b> | <b>0,01467</b> |
|         | <i>Trial and Error</i>       | 83,1831        | 0,93056        | 3,55333        | 0,01867        |
|         | <i>Bayesian Optimization</i> | 41,9529        | 0,67169        | 2,65797        | 144,495        |
|         | <i>Nelder-Mead</i>           | 36,777         | 0,62999        | 2,53893        | 2,68067        |
| 25      | <i>Grid search</i>           | <b>37,2787</b> | <b>0,63441</b> | <b>2,5674</b>  | <b>0,0164</b>  |
|         | <i>Trial and Error</i>       | 92,9105        | 0,95823        | 3,62025        | 0,0212         |
|         | <i>Bayesian Optimization</i> | 42,6756        | 0,67816        | 2,71302        | 135,422        |
|         | <i>Nelder-Mead</i>           | 37,3754        | 0,63534        | 2,57011        | 3,0916         |
| 50      | <i>Grid search</i>           | <b>37,9665</b> | <b>0,64067</b> | 2,62992        | <b>0,0192</b>  |
|         | <i>Trial and Error</i>       | 80,0734        | 0,90674        | 3,50348        | 0,0196         |
|         | <i>Bayesian Optimization</i> | 42,9625        | 0,68072        | 2,73245        | 145,306        |
|         | <i>Nelder-Mead</i>           | 38,0327        | 0,64135        | <b>2,62795</b> | 2,6972         |
| 100     | <i>Grid search</i>           | <b>37,0248</b> | <b>0,63285</b> | <b>2,59886</b> | <b>0,0235</b>  |
|         | <i>Trial and Error</i>       | 78,5215        | 0,89873        | 3,4776         | 0,0241         |
|         | <i>Bayesian Optimization</i> | 42,3308        | 0,67575        | 2,71706        | 168,159        |
|         | <i>Nelder-Mead</i>           | 37,2974        | 0,63497        | 2,60139        | 3,1663         |

Berdasarkan Tabel 4.5, *Grid search* secara konsisten menghasilkan nilai SSE, RMSE, dan MAPE terendah pada simulasi 15, 25, 50, dan 100 iterasi. Nilai-nilai terendah tersebut ditunjukkan dengan penebalan (**bold**) pada tabel sebagai penanda hasil terbaik. Meskipun pada 50 iterasi *Nelder-*

**JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI**  
**Ressy Fitrizka Haryanti , Jose Rizal , Winalia Agwil, Idhia Sriliana, Pepi Novianti**

*Mead* memiliki nilai MAPE sedikit lebih rendah dibandingkan *Grid Search* dengan selisih yang sangat kecil yaitu sebesar 0,0019 dan waktu komputasi *Grid search* yang lebih efisien. Hal ini menunjukkan bahwa *Grid search* tidak hanya mampu mengoptimalkan parameter model *Holt-Winters*, tetapi juga lebih unggul dalam efisiensi waktu dibanding metode optimasi lainnya.

#### 4.4 Inisialisasi

Inisialisasi dalam Metode *Holt-Winters* sangat penting karena mempengaruhi kualitas prediksi. Inisialisasi *Holt-Winters* adalah sebagai berikut:

1. Menghitung nilai awal *level* menggunakan Persamaan (2.9):

$$\begin{aligned} S_{52} &= \frac{1}{52}(y_1 + y_2 + \dots + y_{52}) \\ &= \frac{1}{52}(28.538 + 28.040 + 28.932 + \dots + 33.737) \\ &= 29.033,6 \end{aligned}$$

2. Menghitung nilai awal *trend* menggunakan Persamaan (2.10):

$$\begin{aligned} b_{52} &= \frac{1}{52} \left( \frac{y_{53} - y_1}{52} + \frac{y_{54} - y_2}{52} + \dots + \frac{y_{104} - y_{52}}{52} \right) \\ &= \frac{1}{52} \left( \frac{38.733 - 28.538}{52} + \frac{37.711 - 28.040}{52} + \dots + \frac{32.000 - 33.737}{52} \right) \\ &= 259,5 \end{aligned}$$

3. Menghitung nilai awal musiman *Additive* dengan menggunakan Persamaan (2.11):

$$\begin{aligned} l_1 &= (y_1 - S_s) = 28.538 - 29.033,6 = -495,596 \\ &\vdots \\ l_{52} &= (y_{52} - S_s) = 33.737 - 29.033,6 = 4703,404 \end{aligned}$$

4. Menghitung nilai awal musiman *Multiplicative* dengan menggunakan Persamaan (2.22):

$$\begin{aligned} l_1 &= \frac{y_1}{S_s} = \frac{28.538}{29.033,6} = 0,98293 \\ &\vdots \\ l_{52} &= \frac{y_{52}}{S_s} = \frac{33.737}{29.033,6} = 1,161999 \end{aligned}$$

5. Menghitung nilai prediksi *model Additive* untuk periode ke-53, yaitu pada minggu ke-1 bulan Januari 2024 menggunakan Persamaan (2.15):

$$\begin{aligned} F_{53} &= S_{52} + b_{52}(1) + I_{52-52+1} \\ &= 29.033,6 + 259,5(1) + (-495,596) \\ &= 28.797,49 \end{aligned}$$

Sedangkan untuk *model Multiplicative* gunakan Persamaan (2.19):

$$\begin{aligned} F_{53} &= (S_{52} + b_{52}(1))I_{52-52+1} \\ &= 29.033,6 + 259,5(1) + (0,98293) \\ &= 28.793,06 \end{aligned}$$

Nilai awal ini digunakan untuk menghitung pemulusan *level*, *trend*, dan musiman.

#### 4.5 Estimasi Parameter

Sebelum proses pemulusan, perlu ditentukan parameter  $\alpha$ ,  $\beta$ , dan  $\gamma$  untuk komponen level, tren, dan musiman. Estimasi parameter optimal dalam penelitian ini dilakukan menggunakan Metode *Grid search* dengan evaluasi MAPE. *Grid search* menguji 1.000 kombinasi parameter dari 0,1 hingga 1,0 dengan *increment* 0,1. Sehingga diperoleh parameter optimal berikut.:

**Tabel 4.6.** Parameter *Holt-Winters*

**JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI**  
**Ressy Fitrizka Haryanti , Jose Rizal , Winalia Agwil, Idhia Sriliana, Pepi Novianti**

| $\alpha$ (Alpha) | $\beta$ (Beta) | $\gamma$ (Gamma) |
|------------------|----------------|------------------|
| 1                | 0,1            | 0,1              |

#### 4.6 Pemulusan dan Prediksi


Setelah diperoleh nilai awal dan nilai parameter optimal dengan *Grid search*, hitung pemulusan *level*, *trend*, dan musiman Metode *Holt-Winters Additive* dan *Multiplicative*, sehingga diperoleh prediksi sebagai berikut:

**Tabel 4.7.** Hasil prediksi Metode *Holt-Winters Additive* dan *Multiplicative*


| Bulan | Minggu | Aktual | <i>Fitted Add</i> | <i>Fitted Mult</i> | Bulan | Minggu | Aktual | <i>Fitted Add</i> | <i>Fitted Mult</i> |
|-------|--------|--------|-------------------|--------------------|-------|--------|--------|-------------------|--------------------|
| Jan   | 1      | 38733  | 28797             | 28793              | Juli  | 1      | 46892  | 61137             | 65923              |
|       | 2      | 37711  | 39488             | 39284              |       | 2      | 53277  | 44502             | 43148              |
|       | 3      | 37187  | 39678             | 40015              |       | 3      | 43349  | 53380             | 53095              |
|       | 4      | 37187  | 38840             | 39095              |       | 4      | 43662  | 41550             | 40815              |
| Feb   | 1      | 33632  | 37848             | 37841              | Agust | 1      | 42569  | 42722             | 42368              |
|       | 2      | 35571  | 33871             | 33865              |       | 2      | 42569  | 40268             | 39363              |
|       | 3      | 40431  | 34123             | 33730              |       | 3      | 45477  | 42557             | 42759              |
|       | 4      | 53485  | 42024             | 42302              |       | 4      | 41219  | 46565             | 47255              |
| Mar   | 5      | 57872  | 55671             | 55673              | Sept  | 5      | 40074  | 40839             | 40727              |
|       | 1      | 79144  | 60278             | 60280              |       | 1      | 36862  | 38202             | 37640              |
|       | 2      | 79144  | 82534             | 80790              |       | 2      | 32293  | 35980             | 35804              |
|       | 3      | 54021  | 83448             | 84193              |       | 3      | 32642  | 29169             | 28893              |
| Apr   | 4      | 49762  | 55032             | 55048              | Okto  | 4      | 31814  | 32472             | 32478              |
|       | 1      | 49681  | 47990             | 46196              |       | 1      | 29657  | 32367             | 32283              |
|       | 2      | 56911  | 48821             | 47509              |       | 2      | 26779  | 26850             | 26737              |
|       | 3      | 42810  | 58834             | 59730              |       | 3      | 26779  | 24582             | 24527              |
| Mei   | 4      | 48466  | 42209             | 42046              | Nov   | 4      | 27290  | 26109             | 25912              |
|       | 1      | 50631  | 47772             | 46746              |       | 5      | 27792  | 32534             | 31593              |
|       | 2      | 53044  | 51252             | 51329              |       | 1      | 32000  | 26112             | 25791              |
|       | 3      | 45532  | 52360             | 50355              |       | 2      | 32000  | 31781             | 31358              |
| Juni  | 4      | 51901  | 45558             | 45636              | Des   | 3      | 30000  | 32174             | 31680              |
|       | 5      | 51154  | 54073             | 56378              |       | 4      | 28000  | 29633             | 29121              |
|       | 1      | 50476  | 53390             | 55765              |       | 1      | 25000  | 27523             | 26941              |
|       | 2      | 56952  | 50523             | 50231              |       | 2      | 25000  | 22187             | 22414              |
|       | 3      | 63571  | 58482             | 59353              |       | 3      | 25000  | 18797             | 20504              |
|       | 4      | 56397  | 67113             | 70603              |       | 4      | 32000  | 23658             | 23635              |

Berdasarkan Tabel 4.7, dapat dilihat bahwa sebagian besar nilai prediksi mendekati nilai data aktual. Meskipun demikian, masih terdapat beberapa nilai prediksi yang cukup jauh dari data aktual, dengan selisih yang cukup besar pada titik-titik tertentu. Untuk memberikan gambaran yang lebih jelas mengenai kinerja prediksi, hasil ini juga divisualisasikan melalui plot berikut:

**JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI**  
**Ressy Fitrizka Haryanti , Jose Rizal , Winalia Agwil, Idhia Sriliana, Pepi Novianti**



**Gambar 4.4.** Prediksi model *Additive*



**Gambar 4.5.** Prediksi model *Multiplicative*

Berdasarkan Gambar 4.4 dan 4.5, model *Holt-Winters Additive* menghasilkan prediksi yang lebih halus, terutama saat lonjakan harga tajam seperti pada Maret–April 2024, meskipun cenderung sedikit overestimasi di pertengahan tahun. Sementara itu, model *Multiplicative* lebih responsif terhadap perubahan besar, dengan prediksi lebih mendekati nilai aktual namun lebih fluktuatif. Secara visual, kedua model mampu mengikuti pola tren dan fluktuasi harga dengan baik. Model *Additive* lebih stabil, sedangkan *Multiplicative* lebih adaptif terhadap perubahan besar. Evaluasi model diperlukan untuk menentukan kinerja terbaik di antara keduanya.

#### 4.7 Model *Holt-Winters* dan Peramalan

Setelah pemulusan dengan Metode *Holt-Winters Additive* dan *Multiplicative* menggunakan parameter optimal dari *Grid search*, diperoleh model akhir yang terdiri dari komponen *level*, *trend*, dan musiman. Model ini menjadi dasar untuk meramalkan harga cabai merah pada periode mendatang. Berikut ini model *Holt-Winters Additive*:

$$F_{t+m} = S_{104} + b_{104}m + I_{t-s+m}$$

$$F_{t+m} = 27296,6 + 33,56952m + I_{t-s+m}.$$

Sedangkan model *Holt-Winters Multiplicative* adalah sebagai berikut:

$$F_{t+m} = (S_{104} + b_{104}m)I_{t-s+m}$$

$$F_{t+m} = (27538,76 + (-115,3094m))I_{t-s+m}$$

Berdasarkan kedua model diatas, berikut merupakan peramalan yang dihasilkan untuk 3 bulan pertama pada tahun 2025:

**Tabel 4.8.** Hasil peramalan *Holt-Winters Additive* dan *Multiplicative* tahun 2025

| <i>Point Forecast Additive</i> | <i>Point Forecast Multiplicative</i> |
|--------------------------------|--------------------------------------|
| 26834,57                       | 26955,34                             |
| 26370,14                       | 26373,59                             |
| 27295,71                       | 27097,67                             |
| 28156,28                       | 27754,05                             |
| 28189,85                       | 27635,86                             |
| 28223,42                       | 27517,67                             |
| 26399,99                       | 25689,72                             |
| 26986,56                       | 26085,86                             |
| 27020,13                       | 25972,85                             |
| 27053,7                        | 25859,84                             |
| 26184,26                       | 24929,77                             |

26567,83

25135,64

#### 4.8 Evaluasi Model

Setelah memperoleh hasil prediksi, maka untuk melihat kinerja dari masing-masing model, dilakukan evaluasi hasil prediksi berdasarkan nilai MAPE dan RMSE sebagai berikut:

**Tabel 4.9.** Nilai MAPE dan RMSE

|                                    | MAPE   | RMSE     |
|------------------------------------|--------|----------|
| <i>Holt-Winters Additive</i>       | 11,92% | 7.450,52 |
| <i>Holt-Winters Multiplicative</i> | 12,36% | 7.912,67 |

Berdasarkan Tabel 4.9, diketahui bahwa nilai MAPE *Holt-Winters Additive* adalah 11,92%, sedangkan *Holt-Winters Multiplicative* menghasilkan nilai MAPE yang lebih tinggi yaitu sebesar 12,36%. Berdasarkan Tabel 1 maka dapat disimpulkan bahwa nilai MAPE yang dihasilkan Metode *Holt-Winters Additive* dan *Multiplicative* dapat dikategorikan baik karena memiliki nilai MAPE <20%. Selain itu, berdasarkan nilai RMSE yang memberikan gambaran rata-rata besar kesalahan dalam satuan asli data (Rupiah). *Holt-Winters Additive* memiliki nilai RMSE sebesar 7.450,52 lebih rendah dibandingkan *Holt-Winters Multiplicative* yang menghasilkan nilai RMSE sebesar 7.912,67. Berdasarkan nilai MAPE dan RMSE, dapat disimpulkan bahwa *Holt-Winters Additive* memiliki kinerja yang lebih baik untuk peramalan harga eceran cabai merah di Kota Bengkulu dibandingkan model *Multiplicative*.

#### 4.9 Pembahasan Hasil dan Kontribusi Penelitian

Hasil penelitian ini memberikan kontribusi orisinal dalam bidang peramalan deret waktu musiman, khususnya dalam konteks peramalan harga cabai merah, melalui pendekatan simulasi sistematis untuk mengevaluasi metode optimasi parameter dalam model *Holt-Winters*. Berbeda dengan pendekatan umum yang hanya mengandalkan data aktual, penelitian ini menggunakan data bangkitan dengan parameter yang diketahui untuk membandingkan performa empat metode optimasi *Grid Search*, *Bayesian Optimization*, *Trial and Error*, dan *Nelder-Mead* dalam jumlah iterasi yang bervariasi. Strategi ini memungkinkan penilaian yang lebih objektif terhadap efektivitas dan efisiensi setiap metode dalam kondisi yang terkontrol.

Dalam studi oleh Ilahi dan Agustin (2022), metode *Holt-Winters Additive* digunakan untuk memodelkan nilai tukar petani di Bangka Belitung, dengan pemilihan parameter dilakukan melalui metode coba-coba berdasarkan nilai MAPE terendah. Walaupun menghasilkan akurasi tinggi, proses optimasinya bersifat manual dan belum mencerminkan evaluasi komparatif terhadap pendekatan optimasi yang lebih sistematis. Sementara itu, penelitian Safitri et al. (2017) menunjukkan keunggulan *Holt-Winters* dibandingkan ARIMA dalam konteks jumlah wisatawan, namun tidak membedakan model *additive* dan *multiplicative* serta belum mempertimbangkan metode optimasi parameter dalam model.

Penelitian oleh Dewi dan Listiowarni (2020) menggunakan *Holt-Winters* untuk meramalkan harga bahan pangan, namun fokus utamanya pada perbandingan antar-metode peramalan, bukan pada pemilihan parameter yang optimal. Sebaliknya, penelitian ini menggunakan data mingguan yang secara alami lebih kompleks, serta menuntut proses inisialisasi dan pemilihan parameter yang lebih akurat untuk mencapai performa model yang optimal.

Melalui simulasi dengan parameter diketahui dan skenario iterasi yang bervariasi, penelitian ini memperlihatkan bahwa *Grid Search* secara konsisten memberikan hasil terbaik dalam hal akurasi dan efisiensi waktu. Hasil ini menunjukkan bahwa pemilihan metode optimasi memiliki pengaruh signifikan terhadap kualitas peramalan. Dengan desain eksperimental yang dapat direplikasi dan metodologi yang terukur, pendekatan ini berpotensi menjadi rujukan penting bagi

penelitian-penelitian lanjutan, terutama dalam konteks peramalan deret waktu musiman yang memerlukan akurasi tinggi dan penyesuaian parameter yang optimal.

## 5. KESIMPULAN

Berdasarkan simulasi dengan data bangkitan menunjukkan bahwa Metode *Grid search* menghasilkan estimasi parameter dengan kesalahan prediksi lebih rendah dibanding *Trial and Error*, *Bayesian Optimization*, dan *Nelder-Mead*. Pada berbagai iterasi (15, 25, 50, dan 100), *Grid search* unggul dalam SSE, RMSE, dan MAPE. Meskipun *Nelder-Mead* sedikit lebih baik pada MAPE di iterasi ke-50, selisihnya sangat kecil (0,00197), sementara *Grid search* lebih efisien secara waktu. Ini membuktikan bahwa *Grid search* adalah metode optimasi yang efektif dan efisien untuk estimasi parameter model *Holt-Winters*.

Berdasarkan estimasi parameter optimal menggunakan Metode *Grid search* dengan kriteria evaluasi MAPE, yang menguji kombinasi parameter  $\alpha$ ,  $\beta$ , dan  $\gamma$  dalam rentang 0,1-1,0 dengan 1000 kombinasi. Diperoleh parameter optimal dengan nilai  $\alpha = 1$ ,  $\beta = 0,1$ , dan  $\gamma = 0,1$  yang akan digunakan untuk proses pemulusan model *Holt-Winters Additive* dan *Multiplicative*.

Proses pemulusan *Holt-Winters Additive* dan *Multiplicative* dengan parameter optimal menghasilkan model yang akan digunakan dalam proses peramalan sebagai berikut:

$$F_{t+m}(\text{Additive}) = 27296,6 + 33,56952m + I_{t-s+m}.$$

$$F_{t+m}(\text{Multiplicative}) = (27538,76 + (-115,3094m))I_{t-s+m}.$$

Dengan menggunakan model ini, maka dapat dilakukan peramalan harga eceran cabai merah mingguan di Kota Bengkulu untuk 3 bulan kedepan yaitu pada tahun 2025. Selain itu, kinerja kedua model dapat dilihat berdasarkan nilai MAPE, RMSE, dan *R-Squared* dari prediksi yang dihasilkan. *Model Additive* menghasilkan nilai MAPE sebesar 11,92% lebih kecil dibanding *model Multiplicative* yang memiliki nilai MAPE sebesar 12,36%. Selain itu, berdasarkan nilai RMSE, *Holt-Winters Additive* memiliki nilai RMSE sebesar 7.450,52 yang lebih rendah dibandingkan *model Holt-Winters Multiplicative* yang menghasilkan nilai RMSE sebesar 7.912,67. Hal ini menunjukkan bahwa *model Additive* memiliki kinerja yang lebih baik dalam meramalkan harga cabai merah mingguan di Kota Bengkulu. Kesimpulan harus ringkas dan jelas.

Hasil penelitian ini memiliki implikasi penting terhadap pemantauan dan peramalan harga cabai merah di Kota Bengkulu. Dengan menggunakan metode *Holt-Winters Additive* yang dioptimalkan melalui *Grid search*, diperoleh model yang mampu menghasilkan prediksi dengan kesalahan yang lebih rendah dibandingkan metode lainnya. Akurasi ini menjadikan model sebagai alat bantu yang potensial dalam pengambilan keputusan strategis, terutama bagi dinas terkait seperti Dinas Perdagangan atau Dinas Pertanian dalam merumuskan kebijakan stabilisasi harga dan distribusi. Selain itu, petani dan pedagang dapat memanfaatkan hasil peramalan ini untuk mengatur waktu tanam, panen, dan distribusi agar mendapatkan keuntungan yang lebih optimal. Konsumen juga dapat merasakan manfaatnya melalui ketersediaan harga yang lebih stabil di pasar. Dengan demikian, penerapan model ini tidak hanya bermanfaat dalam konteks akademik, tetapi juga memiliki dampak praktis dalam mendukung pengelolaan komoditas strategis seperti cabai merah secara lebih terencana dan responsif terhadap fluktuasi pasar.

## KONFLIK KEPENTINGAN

Tidak terdapat konflik kepentingan dalam penyusunan dan penulisan jurnal ini. Seluruh proses penelitian, analisis data, serta penyampaian hasil dilakukan secara objektif dan mandiri tanpa adanya pengaruh dari pihak mana pun yang dapat menimbulkan bias.

**DAFTAR PUSTAKA**

- [1] Anggraeni, H.Y.D., 2022. Peramalan Suhu Udara Maksimum Dan Minimum Harian Menggunakan Metode Arima Dan Exponential Smoothing. Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Nahdatul Ulama Al Ghazali, Cilacap.
- [2] Chandrasa, M.A.D., Lesmana, E. & Hertini, E., 2020. Peramalan Jumlah Kedatangan Wisatawan Mancanegara Ke Indonesia Dengan Metode *Holt-Winters* Dan Hubungannya Terhadap Pendapatan Devisa Pariwisata. *Teorema Teor. dan Ris. Mat.*, Vol. 5, No. 2, 230–238.
- [3] Dewi, N., P. & Listiowarni, I., 2020. Implementasi *Holt-Winters* Exponential Smoothing untuk Peramalan Harga Bahan Pangan di Kabupaten Pamekasa. *Digit. Zo. J. Teknol. Inf. dan Komun.*, Vol. 11, No. 2, 223–236.
- [4] Drop, N. & Bohdan, A., 2025. Application of the Holt–Winters Model in the Forecasting of Passenger Traffic at Szczecin–Goleniów Airport (Poland). *Sustainability*, Vol. 17, No. 14, 1–21.
- [5] Fahik, D., S. & Jatipaningrum, M. T., 2021. Peramalan Jumlah Penumpang Penerbangan Internasional Di Bandar Udara Internasional Soekarno Hatta Dengan Metode *Holt-Winters* Exponential Smoothing Dan Seasonal Arima. *Stat. Ind. dan Komputasi*, Vol. 6, No. 1, 77–87.
- [6] Febriyanti, A., N. & Rifai, N.A.K., 2022. Metode Triple Exponential Smoothing *Holt-Winters* untuk Peramalan Jumlah Penumpang Kereta Api di Pulau Jawa. *Bandung Conf. Ser. Stat.*, Vol. 2, No. 2, 152–158.
- [7] Haben, S., Voss, M. & Holderbaum, W., 2023. *Core concepts and methods in load forecasting: With applications in distribution networks*. Springer Nature.
- [8] Kusuma, E., J., Nurmandhani, R., Aryani, L., Pantiawati, I. & Shidik, G.F., 2025. Optimasi Model Extreme Gradient Boosting Dalam Upaya Penentuan Tingkat Risiko Pada Ibu Hamil Berbasis Bayesian Machine Learning Optimization In Determining The Maternal Risk. Vol. 12, No. 1, 111–120.
- [9] Masyuni, I., A., Nugroho, B.K., Mardikawati, B. & Hidayat, D., W., 2020. Peramalan Jumlah Penumpang Angkutan Bus Antar Kota Antar Propinsi Menggunakan Metode *Holt-Winters*. *J. Teknol. Transp. dan Logistik*, Vol. 2, No. 1, 49–56.
- [10] Milniadi, A., D. & Adiwijaya, N.O., 2023. Analisis Perbandingan Model Arima Dan Lstm Dalam Peramalan Harga Penutupan Saham (Studi Kasus : 6 Kriteria Kategori Saham Menurut Peter Lynch). *SIBATIK J. J. Ilm. Bid. Sos. Ekon. Budaya, Teknol. dan Pendidik.*, Vol. 2, No. 6, 1683–1692.
- [11] Mohapatra, A. & Nayak, B., 2018. Parameter estimation of single diode PV module based on Nelder-Mead optimization algorithm. *World J. Eng.*, Vol. 15, No. 1, 70–81.
- [12] Oriekhoe, O. I., Addy, W. A., Okoye, C. C., Oyewole, A. T., Ofodile, O. C. & Ugochukwu, C. E., 2024. The role of accounting in mitigating food supply chain risks and food price volatility. *International Journal of Science and Research Archive*. Vol. 11, No. 1, 2557–2565.
- [13] Pattipeilohy, W., J., Barung, F., M. & Ronsumbre, E., Y., 2024. Analisis Analisis Perubahan Pola Musim dan Distribusi Frekuensi Curah Hujan di Sentani. *Bul. GAW Bariri*, Vol. 5, No. 1, 1–9.
- [14] Prasetyo, V., R., Lazuardi, H., Mulyono, A., A. & Lauw, C., 2021. Penerapan Aplikasi RapidMiner Untuk Prediksi Nilai Tukar Rupiah Terhadap US Dollar Dengan Metode Linear Regression. *J. Nas. Teknol. dan Sist. Inf.*, Vol. 7, No. 1, 8–17.
- [15] Purnama, D. I. & Hendarsin, O.P., 2020. Peramalan Jumlah Penumpang Berangkat Melalui Transportasi Udara di Sulawesi Tengah Menggunakan Support Vector Regression (SVR). *Jambura J. Math.*, Vol. 2, No. 2, 49–59.
- [16] Rais, A., N., Rousyati, R., Thira, I., J., Kholifah, D., N., Purwati, N. & Kristania, Y.M.,

2020. Evaluasi Metode Forecasting pada Data Kunjungan Wisatawan Mancanegara ke Indonesia. *EVOLUSI J. Sains dan Manaj.*, Vol. 8, No. 2, 104–11.
- [17] Safitri, T., Dwidayati, N. & Sugiman, 2017. Perbandingan Peramalan Menggunakan Metode Exponential Smoothing Holt-Winters dan Arima. *Unnes J. Math.*, Vol. 6, No. 1, 48–58.
- [18] Sawalha, S. & Al-Naymat, G., 2025. An Adaptive Holt–Winters Model for Seasonal Forecasting of Internet of Things (IoT) Data Streams. *IoT*, Vol. 6, No. 3, 1–18.
- [19] Sergio, A., Wahyuningsih, S. & Siringoringo, M., 2023. Peramalan Inflasi Kota Balikpapan Menggunakan Metode Singular Spectrum Analysis. *Eksponensial*, Vol. 14, No. 1, 21–30.
- [20] Setyo, V., K. & Abdillah, M.Z., 2024. Prediksi Tonase Penjualan Pt . Immanuel Periode 2015-2024 Dengan Metode Triple Exponential Smoothing Sales Forecasting For Pt . Immanuel Using Triple Exponential Smoothing. Vol. 4, No. 12, 585–595.
- [21] Surur, A. M., 2021. Thorndike’s theory for improving madrasah teacher’s creative thinking and publication. In *International Conference on Engineering, Technology and Social Science (ICONETOS 2020)*, 828-839.
- [22] Takenaga, S., Ozaki, Y. & Onishi, M., 2023. Practical initialization of the Nelder–Mead method for computationally expensive optimization problems. *Optimization Letters*, Vol. 17, No. 2, 283-297.
- [23] Tönnsen, K.C., 2021. The relevance of trial-and-error: Can trial-and-error be a sufficient learning method in technical problem-solving-contexts?. *Techne serien-Forskning i slöjdpedagogik och slöjdetenskap*. Vol. 28, No. 2, 303-312.
- [24] Trianto, A., Muliawati. & Irmanda, H.N., 2022. Penerapan Borderline-SMOTE dan Grid search pada Bagging-SVM untuk Klasifikasi Penyakit Diabetes. *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, Vol. 3, No. 2, 102–113.
- [25] Zayat, W. & Sennaroglu, B., 2020. Performance Comparison of Holt-Winters and SARIMA Models for Tourism Forecasting in Turkey. Vol. 21, No. 2, 63–77.