

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1.Kajian Pustaka**

Tujuan dari kajian pustaka adalah untuk memudahkan analisis terhadap masalah yang sebelumnya sudah dilakukan dan kemudian digunakan sebagai referensi penelitian ini. Penelitian sebelumnya yang terkait dengan topik ini mencakup:

Penelitian [15] yang berfokus pada permasalahan kedatangan pengunjung dengan jumlah yang tidak menentu menggunakan data pengunjung objek wisata Kawah Ijen Bondowoso. Penelitian tersebut menerapkan metode *HWES* multiplikatif yang menghasilkan kesimpulan bahwa perhitungan metode *HWES* multiplikatif tanpa melampirkan data tahun 2020 memiliki *MAPE* terkecil dengan nilai 9%.

Konsep yang sama dengan penelitian ini juga pernah dilakukan sebelumnya yaitu memprediksi penjualan tiket wisata, namun sedikit berbeda pada data yang digunakan. Penelitian [16] menggunakan data penjualan tiket di Saloka *Theme Park* untuk memprediksi penjualan tiket. Dari penelitian tersebut didapat bahwa algoritma *ARIMA* dapat bekerja lebih baik dibandingkan algoritma *Prophet* dan *LSTM* karena mempunyai nilai *RMSE* dan *MAE* paling kecil.

Menggunakan data yang berbeda, penelitian [17] menggunakan metode *HWES* aditif untuk memprediksi kunjungan wisatawan nusantara Kabupaten Sumenep dengan permasalahannya terdapat peningkatan kunjungan yang tidak terduga. Oleh karena itu, perlu dilakukan peramalan yang menghasilkan bahwa metode *HWES* aditif efektif dan membuat prediksi yang akurat. Performa yang dihasilkan dari metode tersebut yaitu nilai *SMAPE* sebesar 13.65%.

Salah satu model peramalan yaitu *HWES* aditif yang digunakan pada penelitian ini sama dengan penelitian [13] untuk memprediksi jumlah wisatawan ke DIY. Data yang digunakan memiliki karakteristik yang mengandung komponen tren dan musiman. Beberapa model *HWES* seperti aditif dan

multiplikatif dibandingkan untuk mendapatkan model yang akurat, didapat bahwa model *HWES* aditif merupakan model terbaik. Model ini memiliki nilai *MAPE* terkecil yaitu 8.28%.

*HWES* yang merupakan salah satu metode pada penelitian ini juga pernah digunakan pada penelitian [18]. Tujuan dari penelitian tersebut untuk meramalkan jumlah pengunjung per periode ke tempat wisata Pantai Gili Labak Sumenep. Menggunakan data jumlah pengunjung, penelitian ini menghasilkan bahwa *HWES* multiplikatif mampu meramalkan jumlah pengunjung Pantai Gili Labak Sumenep dengan nilai *MAPE* terkecil.

Penelitian sebelumnya menerapkan model *ARIMA* yang bertujuan untuk meramalkan kunjungan wisatawan di Provinsi NTB. Hasil penelitian tersebut diperoleh model terbaik, yaitu *ARIMA*(1, 1, 1) karena semua parameternya signifikan dengan nilai  $P < 0.05$  dibandingkan model *ARIMA* yang lain [19].

Penelitian lain yang memiliki tujuan membandingkan beberapa model peramalan juga pernah dilakukan pada penelitian [20]. Menggunakan data kunjungan wisatawan *Bee Jay* Bakau Resort Probolinggo. Dari 2 model peramalan yang dibandingkan, didapat bahwa model *HWES* aditif memiliki nilai *MAPE*, *MAD* dan *MAE* terendah dan memberikan hasil peramalan yang akurat.

Pada penelitian ini memiliki metode yang sama dengan penelitian [21] dengan menggunakan metode *ARIMA*. Penelitian [21] bertujuan membandingkan metode *ARIMA* dan *Double Exponential Smoothing* untuk memprediksi jumlah pengunjung dalam data pengunjung Wana Wisata Sayang Ka'ak. Metode *Double Exponential Smoothing* menghasilkan prediksi yang lebih akurat dalam meramalkan jumlah pengunjung dalam data dengan nilai *error* sebesar 7.77%.

Pada tahun 2023, penelitian [22] melakukan perbandingan metode *ARIMA* dan *HWES* multiplikatif untuk peramalan data jumlah kunjungan pasien langsung dan rujukan di *Public Health Center*. Penelitian tersebut mendapatkan hasil bahwa model *HWES* multiplikatif merupakan model terbaik karena memiliki nilai *MAPE* terkecil secara berturut-turut sebesar 7.90% dan 11.90%.

Model *ARIMA* pada penelitian ini pernah digunakan pada penelitian [14] dengan tujuan untuk membandingkan model *ARIMA* dan dekomposisi. Fokus dari

penelitian [14] yaitu dengan menggunakan model *ARIMA* dan dekomposisi yang diharapkan mampu dalam meramalkan jumlah wisatawan mancanegara. Hasilnya menunjukkan bahwa model *ARIMA* merupakan model terbaik karena memiliki nilai *MAPE* terkecil.

Tabel 2.1 Penelitian Terdahulu

No	Profil Artikel	Rumusan Masalah	Metode	Hasil
1	Hendry Sakti I., dkk; 2023; Implementasi Metode <i>Holt-Winter's Multiplicative</i> Pada Sistem Peramalan Kunjungan Objek Wisata Kawah Ijen Kabupaten Bondowoso [15]	Jumlah kedatangan pengunjung yang tidak menentu dan peningkatan maupun penurunan yang signifikan di bulan tertentu	<i>Holt Winter's Exponential Smoothing Multiplicative</i> , $\alpha$ 0.1; $\beta$ 0.1 dan $\gamma$ 0.1	Hasil dari penelitian tersebut memiliki nilai <i>MAPE</i> terkecil sebesar 9% dibandingkan dengan model lainnya
2	Dienda Rizkya H. R., dkk; 2023; Perbandingan <i>Algoritma ARIMA, Prophet</i> , dan <i>LSTM</i> dalam Prediksi Penjualan Tiket Wisata Taman Hiburan (Studi Kasus : <i>Saloka Theme Park</i> ) [16]	Setelah pandemi <i>Covid-19</i> beroperasi kembali yang mengakibatkan perubahan pengunjung datang ke wisata taman hiburan	<i>ARIMA(1, 0, 1)</i> , <i>Prophet</i> dan <i>LSTM</i> (1 <i>hidden layer</i> : 200 <i>layer</i> , <i>epoch</i> = 100)	Penelitian tersebut mendapatkan hasil, yaitu mempunyai nilai <i>MAE</i> dan <i>RMSE</i> terkecil sebesar 478.887 dan 762.009.
3	Ainun Nawawi, dkk; 2021; Implementasi Metode <i>Holt Winter Additive</i> Untuk Prediksi Kunjungan Wisatawan Nusantara Kabupaten Sumenep [17]	Adanya peningkatan kunjungan wisatawan di Kabupaten Sumenep yang tidak dapat diduga	<i>Holt Winter's Exponential Smoothing Additive</i> , $\alpha$ 0.01; $\beta$ 0.01 dan $\gamma$ 0.37	Penelitian tersebut mendapatkan hasil, yaitu memiliki nilai <i>SMAPE</i> terkecil sebesar 13.65%.

No	Profil Artikel	Rumusan Masalah	Metode	Hasil
4	Cindy T. N., dkk; 2023; Analisis Peramalan Jumlah Wisatawan ke DIY Menggunakan <i>Holt-Winter's Exponential Smoothing</i> [13]	Pandemi <i>Covid-19</i> mengakibatkan jumlah wisatawan di DIY mengalami penurunan	<i>Holt Winter's Exponential Smoothing Additive</i> , $\alpha$ 0.13; $\beta$ 0.08 dan $\gamma$ 1	Penelitian tersebut memperoleh hasil bahwa model terbaik memiliki nilai <i>MAPE</i> terkecil sebesar 8.28% dan hasil peramalannya menunjukkan terjadi peningkatan jumlah wisatawan dari tahun sebelumnya pada tahun 2019.
5	Ainun Rahim, dkk; 2021; Prediksi Jumlah Pengunjung Perperiode Terhadap Tempat Wisata Pantai Menggunakan <i>Triple Exponential Smoothing</i> (Studi Kasus Pantai Gili Labak Sumenep) [18]	Manajemen pengelolaan dan analisis peramalan kedatangan pengunjung wisata dapat dikembangkan sebagai solusi terhadap pengaruh cuaca dan musim, serta bagaimana sumber daya manusia dan letak lokasi dapat dioptimalkan untuk meningkatkan kunjungan wisatawan	<i>Holt Winter's Exponential Smoothing Multiplicative</i> , $\alpha$ 0.1; $\beta$ 0.8, dan $\gamma$ 0.1	Penelitian tersebut menemukan hasil, yaitu mempunyai nilai <i>MAPE</i> terkecil sebesar 0.002%.

No	Profil Artikel	Rumusan Masalah	Metode	Hasil
6	Siti Soraya, dkk; 2024; Peramalan Kunjungan Wisatawan di Provinsi Nusa Tenggara Barat Menggunakan Metode <i>ARIMA Box-Jenkins</i> [19]	Membantu pemerintah dalam persiapan sarana dan prasarana yang memadai menghadapi lonjakan kunjungan wisatawan	<i>ARIMA(1, 1, 1)</i>	Penelitian tersebut mendapatkan hasil, yaitu model sudah memenuhi semua asumsi, yaitu uji signifikansi parameter dengan semua parameternya signifikan yang ditandai nilai $P < 0.05$ dan uji diagnostik bahwa model tersebut sudah <i>white noise</i> karena memiliki statistik uji yang signifikan.
7	Mochammad Fattah, dkk; 2020; Peramalan Kunjungan Wisatawan dan Daya Dukung <i>Bee Jay Bakau Resort</i> Probolinggo [20]	Melakukan estimasi jumlah kunjungan wisatawan ke <i>Bee Jay Bakau Resort</i> di Kota Probolinggo sebagai strategi untuk meningkatkan jumlah kunjungan, dengan mempertimbangkan data kunjungan sebelumnya yang mencakup wisatawan nusantara dan mancanegara	<i>Holt Winter's Exponential Smoothing Additive</i>	Dari penelitian tersebut diperoleh model terbaik karena memiliki nilai <i>MAPE</i> , <i>MAD</i> dan <i>MSE</i> paling kecil.

No	Profil Artikel	Rumusan Masalah	Metode	Hasil
8	Devilia Rahmawati; 2021; <i>Box-Jenkins dan Exponential Smoothing</i> untuk Prediksi Pengunjung Daerah Wisata Sayang Ka'ak Ciamis [21]	Kurangnya daya tarik pengunjung dari luar karena informasi yang belum banyak diketahui masyarakat diluar Kabupaten Ciamis	<i>ARIMA</i> dan <i>Double Exponential Smoothing</i> ( $\alpha$ 0.8 dan $\beta$ 1)	Hasil penelitian tersebut diperoleh rata-rata nilai <i>error</i> paling kecil sebesar 7.77%.
9	Ilham Basri K., dkk; 2023; <i>Forecasting the Number of Patient Visits by ARIMA and Holtwinters Method at the Public Health Center</i> [22]	Pusat kesehatan dapat mempersiapkan fasilitas dan peralatan pendukung layanan secara optimal untuk mengantisipasi peningkatan kunjungan pasien, mengingat kesadaran masyarakat terhadap kesehatan yang semakin meningkat dan dapat menyebabkan antrian panjang atau penumpukan pasien jika tidak ada dokumen pendaftaran yang memadai	<i>ARIMA</i> (0, 1, 1) dan <i>Holt Winter's Exponential Smoothing Multiplicative</i> ( $\alpha$ 0.3; $\beta$ 0.2 dan $\gamma$ 0.1)	Penelitian tersebut mendapatkan hasil bahwa dalam meramalkan jumlah kunjungan pasien langsung dan rujukan di <i>Public Health Center</i> karena memiliki nilai <i>MAPE</i> terkecil secara berturut-turut sebesar 7.90% dan 11.90%.

No	Profil Artikel	Rumusan Masalah	Metode	Hasil
10	Aswi, dkk; 2024; Peramalan Metode Hybrid Dekomposisi- <i>ARIMA</i> dalam Peramalan Jumlah Wisatawan Mancanegara [14]	Untuk mengetahui pertumbuhan wisatawan mancanegara pada tahun yang akan datang	Dekomposisi dan <i>ARIMA</i> (0, 1, 1)	Dari penelitian tersebut diperoleh model terbaik karena memiliki nilai <i>MAPE</i> terkecil sebesar 8.5%.



Dari beberapa kajian pustaka penelitian sebelumnya, untuk penelitian ini yang menjadi referensi utama adalah penelitian [20] karena metode, variabel data dan evaluasi model yang digunakan sama, yaitu metode *HWES* aditif, menggunakan variabel data jumlah pengunjung dan *MAD*. Perbedaan antara penelitian tersebut dan penelitian ini, yaitu evaluasi model yang berbeda dengan penelitian tersebut menggunakan *MAPE*, *MAD* dan *MAE*. Hasil penelitian tersebut diperoleh model terbaik, yaitu *HWES* aditif karena memiliki nilai *MAPE*, *MAD* dan *MAE* terkecil.

Referensi utama lainnya adalah penelitian [14] karena metode dan variabel data yang digunakan sama, yaitu *ARIMA* dan jumlah pengunjung. Perbedaan antara penelitian tersebut dan penelitian ini, yaitu metode dekomposisi dan evaluasi model yang berbeda dengan penelitian tersebut berupa *MAPE* dengan hasilnya menunjukkan bahwa model *ARIMA*(0, 1, 1) merupakan model terbaik karena mempunyai nilai *MAPE* terkecil.

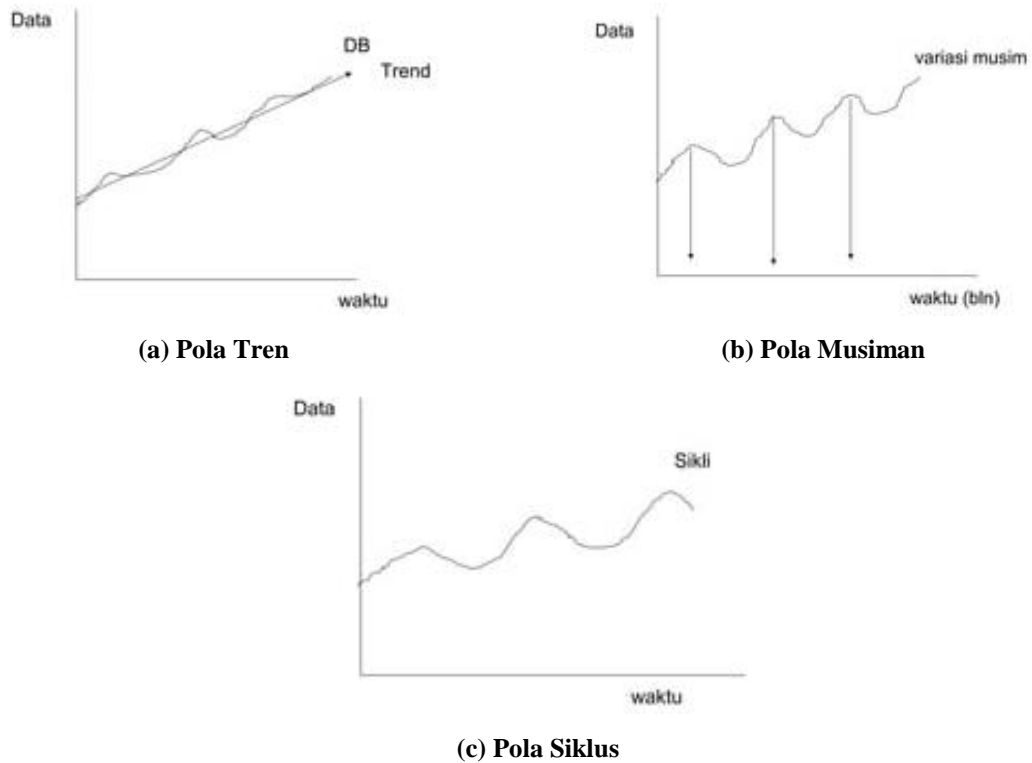
## **2.2.Landasan Teori**

Dasar teori berisi kerangka teoritis yang akan diterapkan untuk menyelesaikan masalah pada penelitian ini sebagai berikut:

### **2.2.1. Time Series**

*Time series* adalah data yang diperoleh berdasarkan urutan waktu dan data berupa periode waktu harian, mingguan, bulanan maupun tahunan. Data *time series* merupakan data yang mencatat nilai-nilai tertentu selama periode waktu tertentu. Data ini memberikan informasi mengenai bagaimana suatu objek atau peristiwa mengalami perubahan dan tren seiring berlalunya waktu [23].

Analisis *time series* adalah teknik peramalan kuantitatif yang menentukan pola data historis yang dikumpulkan berdasarkan *time series*, yang disebut data *time series*. Data *time series* dapat dipandang sebagai representasi realisasi variabel acak, biasanya mempunyai interval waktu yang sama dan diamati dalam jangka waktu tertentu [23].



**Gambar 2.1** Plot Data *Time Series*

Dapat melihat pola pada data yang dikumpulkan. Dalam *time series* terdapat beberapa pola yang terbagi menjadi tiga antara lain pola tren, siklus dan musiman. Pola tren merupakan pola data yang terjadi ketika data bertambah atau berkurang seiring berjalannya waktu. Pola siklus, yaitu pola data yang terjadi ketika data dipengaruhi oleh fluktuasi ekonomi jangka panjang, seperti siklus bisnis. Pola musiman merupakan terjadi pengulangan yang sama pada selang waktu tertentu [23][24].

Analisis data *time series* bertujuan untuk mengidentifikasi pola dan tren serta menggunakan informasi tersebut untuk membuat prediksi atau menyimpulkan. Pemahaman terhadap perubahan dan pola yang berkembang seiring berjalannya waktu dapat diperoleh melalui analisis data *time series* [25].

Data *time series* merupakan gambaran masa lalu dan digunakan untuk memprediksi masa depan. Dalam membuat prediksi, diasumsikan bahwa keadaan di masa depan dipengaruhi oleh kejadian di masa lalu. Dengan kata lain, informasi

dari periode sebelumnya digunakan untuk meramalkan apa yang mungkin terjadi di masa mendatang [23].

### **2.2.2. Peramalan (*Forecasting*)**

Peramalan merupakan proses perhitungan yang digunakan untuk memprediksi situasi yang akan terjadi di masa depan dengan menganalisis kondisi yang telah terjadi pada periode sebelumnya. Hasil peramalan dipengaruhi oleh jenis pola data dan pola tersebut cenderung berulang pada periode waktu yang akan datang. Mengidentifikasi pola pada *time series* digunakan untuk menentukan metode sesuai untuk melakukan analisis data tersebut [26].

Peramalan dapat disusun menggunakan berbagai metode yang dikenal sebagai metode peramalan. Metode peramalan merupakan suatu instrumen untuk memproyeksikan peristiwa secara kuantitatif yang diperkirakan akan terjadi di masa depan, dengan merujuk pada data historis yang relevan. Dengan demikian, metode peramalan memiliki peran penting dalam menyediakan pendekatan analitik terhadap perilaku atau pola yang muncul dari data masa lalu, sehingga dapat memandu pendekatan, pelaksanaan, dan penyelesaian masalah secara sistematis dan praktis, serta memberikan tingkat kepercayaan yang lebih tinggi terhadap hasil peramalan yang dihasilkan atau disusun [26]. Berikut merupakan metode peramalan yang digunakan pada penelitian ini:

#### **1. *Exponential Smoothing***

*Exponential Smoothing* adalah sebuah prosedur yang secara berkelanjutan melakukan perhitungan peramalan pada data terkini [27]. Pendekatan *exponential smoothing* merupakan jenis metode peramalan yang memberikan penekanan yang lebih besar pada data terbaru melalui penggunaan rata-rata bergerak dengan cara eksponensial. Artinya metode tersebut terus-menerus memperbaharui dan menyesuaikan peramalannya seiring dengan penambahan data baru menggunakan konsep rata-rata bergerak dengan cara eksponensial berarti bobot yang diberikan pada pengamatan terbaru lebih besar daripada bobot pada pengamatan yang lebih lama. Dalam metode ini, pengaruh data yang paling baru menjadi lebih signifikan dalam perhitungan rata-rata bergerak [26].

*Exponential Smoothing* adalah teknik yang digunakan untuk meningkatkan akurasi prediksi dari data berurutan sepanjang waktu. Beberapa keuntungan dari teknik ini termasuk kemampuan untuk beroperasi dengan efisien tanpa memerlukan jumlah data yang besar dari satu periode ke periode berikutnya, dan kemampuan untuk menangani data yang berkaitan dengan tren atau musiman tanpa mengeluarkan biaya yang besar [28]. Pendekatan *Exponential Smoothing* terdiri dari tiga jenis, yakni *Single Exponential Smoothing (SES)*, *Double Exponential Smoothing (DES)* dan *Triple Exponential Smoothing (TES)*.

Dalam metode *SES*, nilai observasi yang lebih tua diberi bobot yang semakin berkurang secara eksponensial. Nilai terbaru memiliki bobot yang lebih besar daripada nilai yang lebih lama, sehingga memberikan rata-rata bergerak eksponensial dari semua nilai sebelumnya. *SES* hanya menggunakan parameter level saja, yaitu *alpha* ( $\alpha$ ) [28].

*Holt's Exponential Smoothing* dan *Brown's Exponential Smoothing* adalah jenis metode *DES* yang menggunakan dua konstanta pemulusan level dan tren secara berturut-turut disimbolkan dengan  $\alpha$  dan  $\beta$  yang masing-masing memiliki nilai antara 0 dan 1. Tujuannya adalah untuk memperoleh tren data baru untuk menghilangkan dan menempatkan perkiraan nilai data [28].

Dalam penelitian ini, metode *TES* yang diterapkan adalah *Holt Winter's Triple Exponential Smoothing (HWES)* dengan menggunakan tiga konstanta pemulusan, yaitu konstanta pemulusan level ( $\alpha$ ), konstanta pemulusan untuk tren ( $\beta$ ) dan konstanta pemulusan musiman ( $\gamma$ ). Peramalan menggunakan metode *HWES* dimulai dengan mengatur parameter  $\alpha$ ,  $\beta$  dan  $\gamma$  untuk memulai proses inisialisasi atau pemulusan awal level, tren dan musiman dalam serangkaian persamaan kemudian memungkinkan perhitungan nilai peramalan [28].

## **2. Holt Winter's Exponential Smoothing (HWES)**

Metode *time series* sering digunakan untuk data yang menunjukkan tren atau pola musiman. Peramalan dalam metode ini adalah hasil dari rata-rata berbobot dari pengamatan masa lalu, menunjukkan bobotnya menurun secara eksponensial seiring dengan jarak waktu dari pengamatan tersebut. Salah satu

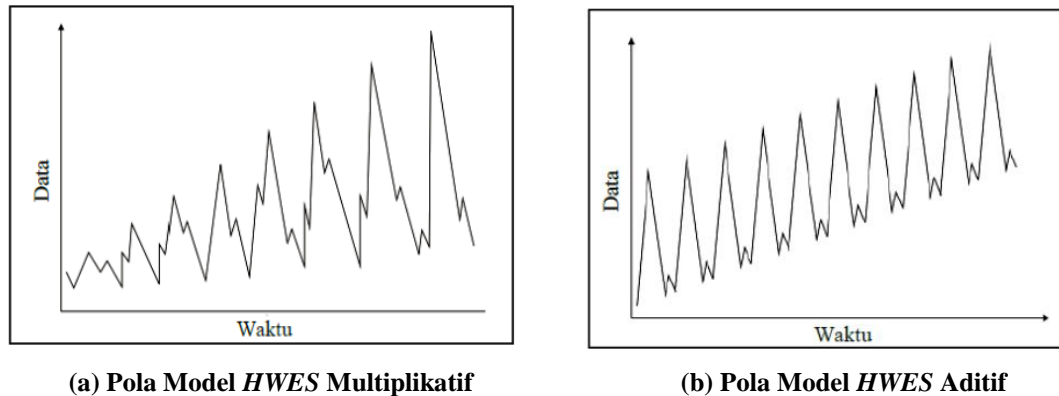
teknik yang populer dalam metode ini adalah model *HWES*, yang terdiri dari tiga komponen: level, tren, dan musiman. Model tersebut efektif dalam menangkap perubahan dalam tren dan musiman dari data *time series* untuk menghasilkan ramalan yang lebih halus [29].

Metode *HWES* memiliki kelebihan, yaitu dapat meramalkan data dengan tingkat akurasi yang baik dan dapat mempertimbangkan faktor tren dan musiman. Sedangkan, untuk kekurangan dari metode *HWES* adalah memerlukan data historis yang cukup untuk meramalkan dengan akurasi yang baik dan parameter  $\alpha$ ,  $\beta$  dan  $\gamma$  harus dipilih dengan hati-hati untuk menghasilkan peramalan yang akurat [30].

*HWES* adalah suatu algoritma peramalan yang memperhitungkan data tren musiman, mirip dengan metode *double exponential smoothing*, tetapi dengan penggunaan konstanta *gamma* tambahan. Hal ini bertujuan untuk menghasilkan tingkat pemulusan yang lebih rendah sehingga mendapatkan hasil peramalan yang lebih akurat [31]. Metode *HWES* memiliki tiga parameter, yaitu *alpha* ( $\alpha$ ) menunjukkan level, *beta* ( $\beta$ ) menunjukkan tren dan *gamma* ( $\gamma$ ) menunjukkan musiman [8] dengan nilai parameter yang berada dalam rentang antara 0 hingga 1 [32]. Parameter level menunjukkan nilai rata-rata umum dari data pada suatu waktu. Parameter tren memberikan perkiraan tentang perubahan umum atau kecenderungan dalam *time series*. Sedangkan parameter musiman membantu mengidentifikasi dan memodelkan pola-pola yang berulang dalam data, seperti kenaikan atau penurunan kunjungan wisatawan pada satu periode musiman seperti musim bulanan atau tahunan. Metode *HWES* dapat diterapkan pada data yang bersifat *non-stasioner* [33].

Apabila data *time series* tidak menunjukkan pola yang konsisten atau linear, maka metode *triple exponential smoothing* digunakan untuk mengatasi tren dan pola musiman dalam data tersebut. Meskipun begitu, metode ini memiliki kemampuan untuk mengelola faktor musiman secara langsung. Dalam metode *HWES* terdapat dua metode perhitungan yang digunakan, yaitu metode perkalian musiman yang disebut sebagai metode multiplikatif dan metode penambahan musiman yang disebut sebagai metode aditif [18].

Penggunaan model aditif digunakan ketika fluktuasi musiman pada grafik data asli cenderung stabil, sementara model multiplikatif digunakan jika fluktuasi musiman pada grafik data asli menunjukkan variasi [34].



Gambar 2.2 Pola Model *HWES* [8]

Dalam penelitian ini, digunakan model *HWES* aditif karena grafik pada data cenderung stabil. Berikut merupakan persamaan model aditif sebagai berikut:

**(1) Menentukan nilai inisialisasi**

Perhitungan menentukan nilai inisialisasi yang terdiri dari nilai pemulusan awal level, tren dan musiman secara berturut-turut menggunakan persamaan (2.1), (2.2) dan (2.3).

**Menentukan nilai pemulusan awal level ( $S_l$ )**

$$S_l = \frac{1}{l} (y_1 + y_2 + \dots + y_l) \quad (2.1)$$

Keterangan:

$S_l$  : nilai pemulusan awal level

$y_l$  : nilai aktual periode ke- $l$

$l$  : panjang musim

**Menentukan nilai pemulusan awal tren ( $b_l$ )**

$$b_l = \frac{1}{l} \left( \frac{y_{l+1} - y_1}{l} + \frac{y_{l+2} - y_2}{l} + \dots + \frac{y_{l+l} - y_l}{l} \right) \quad (2.2)$$

Keterangan:

$b_l$  : nilai pemulusan awal tren

$y_l$  : nilai aktual periode ke- $l$

$l$  : panjang musim

**Menentukan nilai pemulusan awal musiman ( $I_l$ )**

$$I_l = (y_l - S_l) \quad (2.3)$$

Keterangan:

$I_l$  : nilai pemulusan awal musiman

$y_l$  : nilai aktual periode ke- $l$

$S_l$  : nilai pemulusan awal level

**(2) Menentukan nilai parameter  $\alpha$ ,  $\beta$  dan  $\gamma$**

Menentukan nilai parameter  $\alpha$ ,  $\beta$  dan  $\gamma$  ditentukan secara *random* sesuai dalam rentang ketiga nilai parameter tersebut antara 0 hingga 1 dengan bantuan *R Studio* yang menghasilkan beberapa kombinasi ketiga parameter yang terbentuk berdasarkan rentang nilai ketiga parameter tersebut [32].

**(3) Menentukan nilai pemulusan keseluruhan level ( $S_t$ )**

Untuk menghitung nilai pemulusan keseluruhan level dengan persamaan (2.4).

$$S_t = \alpha(y_t - I_{t-l}) + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2.4)$$

Keterangan:

$\alpha$  : konstanta pemulusan  $0 < \alpha < 1$

$y_t$  : nilai aktual periode ke- $t$

$S_t$  : nilai pemulusan level periode ke- $t$

$S_{t-1}$  : nilai pemulusan level periode ke- $t - 1$

$b_{t-1}$  : nilai awal pemulusan tren periode ke- $t - 1$

$I_{t-l}$  : nilai pemulusan awal musiman periode ke- $t - l$

$l$  : panjang musim

**(4) Menentukan nilai pemulusan keseluruhan tren ( $b_t$ )**

Perhitungan menentukan nilai pemulusan keseluruhan tren dapat menggunakan persamaan (2.5).

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1} \quad (2.5)$$

Keterangan:

$\beta$  : konstanta pemulusan  $0 < \beta < 1$

- $S_t$  : nilai pemulusan level periode ke- $t$   
 $S_{t-1}$  : nilai pemulusan level periode ke- $t - 1$   
 $b_t$  : nilai pemulusan tren periode ke- $t$   
 $b_{t-1}$  : nilai awal pemulusan tren periode ke- $t - 1$

**(5) Menentukan nilai pemulusan keseluruhan musiman ( $I_t$ )**

Untuk menghitung nilai pemulusan keseluruhan musiman menggunakan persamaan (2.6).

$$I_t = \gamma(y_t - S_t) + (1 - \gamma)I_{t-l} \quad (2.6)$$

Keterangan:

- $\gamma$  : konstanta pemulusan  $0 < \gamma < 1$   
 $y_t$  : nilai aktual periode ke- $t$   
 $S_t$  : nilai pemulusan level periode ke- $t$   
 $I_{t-l}$  : nilai pemulusan awal musiman periode ke- $t - l$   
 $I_t$  : nilai pemulusan musiman periode ke- $t$

**(6) Menentukan nilai peramalan pada periode mendatang ( $F_{t+m}$ )**

Berikut merupakan persamaan model *HWES* yang dapat dihitung menggunakan persamaan (2.7) dengan pendekatan model aditif yang digunakan untuk menghitung nilai peramalan pada periode mendatang.

$$F_{t+m} = S_t + b_t m + I_{t-l+m} \quad (2.7)$$

Keterangan:

- $S_t$  : nilai pemulusan level periode ke- $t$   
 $b_t$  : nilai pemulusan tren periode ke- $t$   
 $F_{t+m}$  : nilai peramalan pada periode mendatang  
 $I_{t-l+m}$  : nilai pemulusan musiman periode ke- $t - l + m$   
 $m$  : periode yang akan diramalkan  
 $l$  : panjang musim

$S_l$  merupakan nilai pemulusan awal untuk level atau tingkat data pada awal periode peramalan dan dapat dilihat sebagai perkiraan awal atau pendugaan awal terhadap nilai rata-rata data.  $b_l$  merupakan nilai pemulusan awal untuk tren atau kecenderungan data pada awal periode peramalan dan estimasi awal terhadap



tingkat perubahan data dari waktu ke waktu.  $I_l$  merupakan nilai pemulusan awal untuk komponen musiman data pada awal periode peramalan dan estimasi awal terhadap pola musiman dalam data [34].

$\alpha$  merupakan parameter pemulusan untuk level,  $\beta$  merupakan parameter pemulusan untuk tren,  $\gamma$  merupakan parameter pemulusan untuk komponen musiman. Rentang nilai  $\alpha, \beta$ , dan  $\gamma$  antara 0 hingga 1 yang menentukan seberapa cepat model merespons perubahan level, tren maupun komponen musiman dalam data aktual. Semakin kecil  $\alpha, \beta$ , dan  $\gamma$  maka semakin lambat model merespons perubahan dalam level, tren dan musiman sehingga menghasilkan level, tren dan musiman yang lebih halus atau stabil [34].

$y_l$  dan  $y_t$  merupakan data aktual yang diamati pada periode waktu ke- $l/t$ .  $S_t, b_t$ , dan  $I_t$  secara berturut-turut merupakan nilai yang dihitung untuk level, tren dan komponen musiman data pada periode ke- $t$ .  $S_{t-1}$ , dan  $b_{t-1}$  secara berturut-turut merupakan nilai yang dihitung untuk level dan tren data pada periode sebelumnya.  $I_{t-l}$  merupakan nilai yang dihitung untuk komponen musiman data pada periode ke- $t - l$  [34].

$F_{t+m}$  merupakan peramalan atau estimasi nilai data pada periode waktu mendatang.  $I_{t-l+m}$  merupakan nilai yang dihitung untuk komponen musiman data pada periode ke- $t - l + m$ .  $m$  dan  $l$  secara berturut-turut merupakan jumlah periode waktu ke depan yang ingin dihasilkan peramalan dan jumlah periode waktu yang membentuk 1 siklus musiman dalam data *time series* [34].

### 3. Autoregressive (AR)

*Autoregressive* adalah proses yang berasal dari regresinya sendiri dan terdiri dari model linier dasar untuk proses stasioner. Model tersebut ada banyak tingkatan dengan konstanta tersebut sebagai koefisien [35]. Berikut merupakan persamaan (2.8) model AR.

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (2.8)$$

Keterangan:

$\mu$  : rata-rata dari data aktual

$Z_t$  : *time series* stasioner

- $Z_{t-p}$  : variabel bebas  
 $\phi_p$  : koefisien parameter *autoregressive* ke- $p$   
 $a_t$  : sisaan pada saat ke- $t$

$\mu$  merupakan nilai rata-rata dari distribusi data aktual yang diamati.  $Z_t$  merupakan *time series* yang stasioner tidak memiliki tren yang jelas atau pola musiman serta memiliki sifat statistik yang tetap sepanjang waktu dan melambangkan model *AR* yang sering digunakan *time series* stasioner sebagai basis untuk peramalan.  $Z_{t-p}$  merupakan variabel bebas yang digunakan dalam model *AR* untuk meramalkan nilai  $Z_t$  pada waktu  $t$  dan berupa nilai  $Z_t$  pada waktu sebelumnya.  $\phi_p$  merupakan koefisien yang menghubungkan  $Z_t$  dengan nilai-nilai sebelumnya  $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$  dalam model *AR(p)* dan diperkirakan dari data historis untuk meramalkan nilai  $Z_t$  di masa depan.  $a_t$  merupakan sisaan atau residual dalam model *AR* yang mencerminkan kesalahan antara nilai aktual dan nilai yang diramalkan oleh model *AR* [35].

#### 4. *Moving Average (MA)*

Metode *MA* adalah metode peramalan yang melibatkan pengambilan sekelompok nilai observasi dan nilai rata-rata dari kelompok tersebut dianggap sebagai perkiraan untuk periode mendatang [36]. Metode tersebut digunakan ketika data sebelumnya tidak memiliki faktor tren atau pola musiman [5]. Berikut merupakan persamaan (2.9) model *MA*.

$$Z_t = \mu - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} + a_t \quad (2.9)$$

Keterangan:

- $\mu$  : rata-rata dari data aktual  
 $Z_t$  : *time series* stasioner  
 $a_{t-q}$  : variabel bebas  
 $\theta_q$  : koefisien parameter *autoregressive* ke- $q$   
 $a_t$  : sisaan pada saat ke- $t$

$\mu$  merupakan nilai rata-rata dari distribusi data aktual yang diamati.  $Z_t$  merupakan *time series* yang stasioner tidak memiliki tren yang jelas atau pola musiman serta memiliki sifat statistik yang tetap sepanjang waktu dan melambangkan model *MA* yang sering digunakan *time series* stasioner sebagai basis untuk peramalan.  $a_{t-q}$  merupakan variabel bebas yang digunakan model *MA* untuk meramalkan nilai  $Z_t$  pada waktu  $t$  dan berupa nilai  $Z_t$  pada waktu sebelumnya.  $\theta_q$  merupakan koefisien yang menghubungkan  $Z_t$  dengan nilai-nilai sebelumnya  $a_{t-1}, a_{t-3}, \dots, a_{t-q}$  dan diperkirakan dari data historis untuk meramalkan nilai  $Z_t$  di masa depan.  $a_t$  merupakan sisaan atau residual dalam model *MA* yang mencerminkan kesalahan antara nilai aktual dan nilai yang diramalkan oleh model *MA* [36].

### 5. *Autoregressive Integrated Moving Average (ARIMA)*

*George Box* dan *Gwilym Jenkins* pertama kali mengembangkan model *ARIMA* untuk pemodelan *time series* pada tahun 1976 [37]. Model *ARIMA* digunakan untuk melakukan peramalan dalam jangka waktu yang singkat. Namun, jika diterapkan dalam jangka waktu yang lebih panjang, hasil peramalannya menjadi kurang akurat.

Secara umum, model *ARIMA* dinyatakan dalam notasi  $(p, d, q)$ , dengan  $p$  mewakili komponen *AR*,  $d$  adalah proses *differencing*, dan  $q$  mengacu pada komponen *MA*. Terdapat serangkaian langkah yang harus diikuti sebelum melakukan peramalan, termasuk tahap identifikasi data (pengujian stasioneritas data), analisis fungsi *ACF* dan *PACF*, estimasi model dan akhirnya proses peramalan [12]. Berikut merupakan persamaan (2.10) model *ARIMA*.

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} + a_t \quad (2.10)$$

Keterangan:

$\mu$  : rata-rata *time series*

$Z_{t-p}$  : variabel bebas

$\phi_p$  : koefisien parameter *autoregressive* ke- $p$

$a_{t-q}$  : variabel bebas

$\theta_q$  : koefisien parameter *autoregressive* ke- $q$

$a_t$  : sisaan pada saat ke- $t$

$\mu$  merupakan nilai rata-rata dari distribusi data aktual yang diamati.  $Z_{t-p}$  merupakan nilai dari *time series* pada waktu sebelumnya tepatnya  $Z$  pada waktu  $t - p$  dan merupakan variabel bebas yang digunakan dalam model *AR* untuk meramalkan nilai *time series* pada waktu  $t$ .  $\theta_p$  merupakan koefisien yang menghubungkan  $Z_{t-p}$  dengan nilai-nilai sebelumnya dalam model *AR*( $p$ ) dan diperkirakan dari data historis untuk meramalkan nilai *time series* di masa depan.  $a_{t-q}$  merupakan nilai dari *time series* pada waktu sebelumnya tepatnya  $a$  pada waktu  $t - q$  dan merupakan variabel bebas yang digunakan dalam model *MA* untuk meramalkan nilai *time series* pada waktu  $t$ .  $\theta_q$  merupakan koefisien yang menghubungkan  $a_{t-q}$  dengan nilai-nilai sebelumnya dalam model *MA*( $q$ ) dan diperkirakan dari data historis untuk meramalkan nilai *time series* di masa depan.  $a_t$  merupakan sisaan atau residual dalam model *ARIMA* yang mencerminkan kesalahan antara nilai aktual dan nilai yang diramalkan oleh model *ARIMA* [12].

### 2.2.3. Autocorrelation Function (ACF)

*ACF* adalah penghitungan autokorelasi yang didasarkan pada varian dan kovariansi data serta digunakan untuk mengevaluasi adanya korelasi antara nilai-nilai data pada waktu yang sama. Plot *ACF* berguna untuk mengidentifikasi apakah data tersebut merupakan data stasioner atau tidak [38]. Penggunaan *ACF* ini berguna untuk menentukan parameter dalam model *AR* [39]. Untuk menghitung *ACF* yang dapat dihitung dengan persamaan (2.11), berikut adalah rumusnya.

$$\hat{p}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (2.11)$$

Keterangan:

$\hat{p}_k$  : fungsi autokorelasi

$Z_t$  : data observasi ke- $t$

$\bar{Z}$  : rata-rata data observasi

$Z_{t+k}$  : data observasi ke- $t + k$

$\hat{\rho}_k$  merupakan ukuran statistik yang mengukur seberapa besar korelasi antara nilai-nilai *time series* dengan dirinya sendiri pada lag  $k$  dan untuk mengevaluasi apakah ada pola atau hubungan temporal antara observasi *time series* pada lag tertentu.  $Z_t$  merupakan nilai aktual dari *time series* pada waktu tertentu yang digunakan dalam analisis atau pemodelan data.  $\bar{Z}$  merupakan nilai rata-rata dari seluruh rangkaian data observasi.  $Z_{t+k}$  merupakan nilai observasi dari *time series* pada waktu  $t + k$  yang digunakan dalam analisis untuk meramalkan nilai di masa depan atau mengevaluasi pola atau tren dalam data [39].

#### 2.2.4. Partial Autocorrelation Function (PACF)

*PACF* menunjukkan tingkat korelasi parsial antara observasi pada waktu ke- $t$  (dinotasikan  $X_t$ ) dan observasi sebelumnya pada waktu-waktu sebelumnya (dinotasikan dengan  $X_{t-1}, X_{t-2}, \dots, X_{t-k}$ ) [40]. Fungsi *PACF* berguna untuk mengidentifikasi parameter dalam model *MA* [39]. Dalam perhitungan, *PACF* melibatkan korelasi antara  $X_t$  dan  $X_{t+k}$ , dengan menghilangkan data antara  $X_t$  dan  $X_{t+k}$  terlebih dahulu yang artinya data yang dihilangkan adalah data  $X_{t+1}$  sampai dengan  $X_{t+k-1}$  [12]. Berikut merupakan rumus untuk menghitung *PACF* dengan menggunakan persamaan (2.12).

$$\hat{\phi}_{k+1, j+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.12)$$

Keterangan:

$\hat{\phi}_{k+1, j+1}$  : fungsi autokorelasi parsial

$\hat{\rho}_{k+1}$  : fungsi autokorelasi

$\hat{\phi}_{k+1, j+1}$  merupakan koefisien autokorelasi parsial antara variabel pada lag  $k + 1$  dan  $j + 1$  artinya mengukur korelasi antara  $Z_{t-k-1}$  dengan  $Z_{t-j-1}$  setelah mempertimbangkan efek atau menghilangkan pengaruh variabel lainnya dari semua variabel antara  $Z_{t-k-1}$  dan  $Z_{t-j-1}$ .  $\hat{\rho}_{k+1}$  merupakan koefisien autokorelasi

antara variabel pada lag  $k + 1$  artinya mengukur seberapa kuat hubungan antara  $Z_t$  dan  $Z_{t-k-1}$  [12].

### 2.2.5. Teknik Evaluasi Kesesuaian Model

Teknik evaluasi kesesuaian model adalah serangkaian metode dan kriteria yang digunakan untuk mengukur sejauh mana model statistik atau matematis yang telah dikembangkan cocok dengan data yang telah diamati. Tujuannya adalah memastikan bahwa model tersebut mampu memberikan penjelasan yang akurat terhadap data dan menghasilkan hasil yang dapat diandalkan dalam analisis dan peramalan [41]. Terdapat beberapa teknik evaluasi kesesuaian model di antaranya, yaitu *Root Mean Square Error (RMSE)* dan *Mean Absolute Deviation (MAD)*.

#### a. *RMSE*

Tujuan dari *RMSE*, yaitu untuk mengevaluasi model peramalan yang digunakan untuk mengukur akurasi hasil peramalan suatu model. Hasil perhitungan *RMSE*, yaitu nilai rata-rata kuadrat dari jumlah *error* pada model peramalan [42]. Nilai *RMSE* rendah artinya nilai hasil dari model peramalan mendekati nilai aktual [43]. Perhitungan nilai *RMSE* dapat menggunakan persamaan (2.13).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.13)$$

Keterangan:

$\hat{y}_i$  : nilai peramalan ke- $i$

$y_i$  : nilai aktual ke- $i$

$n$  : jumlah data

#### b. *MAD*

*MAD* merujuk pada rata-rata dari nilai absolut dari seluruh kesalahan dalam proses peramalan. Penggunaan nilai absolut berguna untuk memastikan bahwa kesalahan negatif dan positif tidak saling membatalkan satu sama lain. Semakin kecil nilai *MAD* yang diperoleh, semakin akurat hasil peramalan [44]. Persamaan (2.14) berikut dapat digunakan untuk menghitung nilai *MAD*.

$$MAD = \frac{1}{n} \sum_{t=1}^n |y_t - \bar{y}| \quad (2.14)$$

Keterangan:

$\bar{y}$  : rata-rata dari data aktual

$y_i$  : nilai aktual ke- $i$

$n$  : jumlah data

### 2.2.6. Stasioneritas Data

Stasioneritas data merupakan kondisi dengan rata-rata dan variansi data tetap konstan sepanjang *time series*. Stasioneritas menunjukkan bahwa data tidak mengalami peningkatan atau penurunan. Data secara kasar harus horizontal sepanjang sumbu waktu dengan kata lain fluktuasi data tidak bergantung pada waktu dan tetap konstan di sekitar nilai rata-rata. Untuk mengetahui kestasioneran variansi data, dapat digunakan estimasi *lambda* pada pemeriksaan transformasi *Box-Cox*. Sementara itu, kestasioneran data pada rata-ratanya dapat diperiksa dengan tiga cara: melihat plot *time series* data, menggunakan plot *ACF* dan melakukan uji stasioneritas *ADF* (*Augmented Dickey Fuller*). Uji stasioneritas data *time series* adalah proses untuk menentukan apakah data tersebut memiliki sifat stasioner atau tidak [45]. Berikut merupakan pengambilan keputusan dari pemeriksaan *Box-Cox* dan uji *ADF*:

1. Pemeriksaan stasioner terhadap variansi melalui pemeriksaan *Box-Cox*. Jika nilai  $\hat{\lambda}$  (*lambda*) mendekati atau sama dengan 1 maka data tersebut stasioner terhadap variansi. Apabila nilai  $\hat{\lambda}$  tidak mendekati atau sama dengan 1 maka data tersebut perlu dilakukan tahap transformasi data [46].
2. Pemeriksaan stasioner terhadap rata-rata menggunakan uji *ADF*. Berikut merupakan rumusan hipotesis dan dasar pengambilan keputusan uji *ADF*:

#### Rumusan Hipotesis:

$H_0$  : data tidak stasioner

$H_1$  : data stasioner

#### Dasar Pengambilan Keputusan:

$H_0$  diterima jika nilai *p-value* > nilai taraf signifikansi atau *alpha* 0,05 atau 5% [47] atau jika nilai *ADF* hitung > nilai *ADF* tabel [48].

Berikut adalah rumus perhitungan statistik uji *ADF* pada persamaan (2.15).

$$\tau = \frac{\rho-1}{SE(\rho)} \quad (2.15)$$

Keterangan:

$\rho$  : estimasi parameter *autoregressive*

$SE(\rho)$  : *standard error* dari estimasi  $\rho$

Proses *differencing* data dilakukan jika data tidak stasioner terhadap rata-rata [49]. *Differencing* adalah hasil perbedaan antara satu waktu dengan waktu yang lain. Tujuan dari proses *differencing*, yaitu agar pola data menjadi stasioner pada nilai rata-rata atau berfluktuasi di sekitar titik nol [50]. Jika proses *differencing* pertama dihasilkan bahwa pola data belum juga stasioner maka dilakukan kembali proses *differencing* selanjutnya sampai pola data stasioner [51]. Untuk proses *differencing* dapat dihitung menggunakan rumus persamaan (2.16).

$$\Delta y_t = y_t - y_{t-1} \quad (2.16)$$

Keterangan:

$\Delta y_t$  : *time series* yang telah dilakukan *differencing*

$y_t$  : nilai *time series* pada waktu ke- $t$

$y_{t-1}$  : nilai *time series* pada waktu sebelumnya ke- $t - 1$

### 2.2.7. Transformasi Data

Transformasi data adalah proses mengubah bentuk data asli menjadi bentuk lain sehingga data dapat memenuhi asumsi-asumsi yang mendasari analisis ragam. Tujuan transformasi data adalah untuk mengubah skala pengukuran data asli menjadi bentuk lain yang memungkinkan analisis ragam yang lebih efektif. Transformasi data sangat penting dalam analisis statistik karena memungkinkan data memenuhi asumsi-asumsi yang diperlukan untuk analisis ragam. Berikut jenis transformasi data yang digunakan dalam penelitian ini adalah [49]:

#### a. Transformasi Akar Kuadrat

Pada penelitian ini, menggunakan jenis transformasi data akar kuadrat karena untuk mengurangi adanya data *outlier* pada data jumlah pengunjung. Transformasi akar kuadrat digunakan untuk menggabungkan ragam data yang



tidak homogen. Rumus transformasi akar kuadrat dengan  $x$  adalah data aktual dan  $y$  adalah hasil transformasi yang dapat dihitung menggunakan persamaan (2.17) [49].

$$y = \sqrt{x} \quad (2.17)$$