

BAB II

TINJAUAN PUSTAKA

2.1 Pengertian Pariwisata

Menurut Hunziger dan Krapf dari Swiss dalam *Grundriss Der Allgemeinen Femderverkehrslehre* (2008) menyatakan pariwisata adalah keseluruhan jaringan dan gejala-gejala yang berkaitan dengan tinggalnya orang asing disuatu tempat dengan syarat orang tersebut tidak melakukan suatu pekerjaan penting yang memberi keuntungan yang bersifat permanen maupun sementara.

Menurut definisi yang luas pariwisata merupakan suatu perjalanan dari satu tempat ke tempat lain yang bersifat sementara dan dilakukan perorangan maupun kelompok sebagai usaha mencari keseimbangan atau keselarasan dan kebahagiaan dengan lingkungan hidup dalam dimensi sosial, budaya, alam dan ilmu. Dalam kesimpulannya pariwisata adalah keseluruhan fenomena (gejala) dan hubungan-hubungan yang ditimbulkan oleh perjalanan dan persinggahan manusia di luar tempat tinggalnya dengan maksud bukan untuk tinggal menetap (Soebagio, 2012). Dengan demikian bisa dikatakan bahwa pariwisata adalah kegiatan untuk mengisi waktu luang, bersenang-senang, bersantai, studi, kegiatan agama dan mungkin untuk kegiatan olahraga. Selain itu juga semua kegiatan tersebut dapat memberi keuntungan bagi pelakunya baik secara fisik maupun mental.

Dalam Undang-undang RI nomor 10 tahun 2009 tentang kepariwisataan dijelaskan bahwa:

- a. Wisata merupakan kegiatan perjalanan yang dilakukan oleh seseorang atau sekelompok orang dengan berkunjung ke suatu tempat tertentu dengan tujuan rekreasi atau hiburan, pengembangan diri atau mempelajari keunikan daya tampung wisata yang dikunjungi.
- b. Wisatawan merupakan orang yang melakukan perjalanan wisata.
- c. Pariwisata merupakan berbagai macam kegiatan wisata dan didukung oleh berbagai fasilitas serta layanan yang disediakan oleh masyarakat, pengusaha dan juga pemerintah.
- d. Kepariwisata merupakan keseluruhan kegiatan yang terkait dengan pariwisata yang bersifat multidimensi dan multidisiplin sebagai wujud

kebutuhan setiap orang dan negara, serta interaksi antara wisatawan dengan masyarakat setempat.

- e. Usaha pariwisata merupakan usaha yang menyediakan barang dan jasa bagi wisatawan dan penyelenggara pariwisata.
- f. Pengusaha pariwisata merupakan orang atau sekelompok orang yang melakukan kegiatan usaha pariwisata.

2.2 Analisis Deret waktu

Deret waktu pada awalnya dikenalkan oleh George E. P. Box dan Gwilym M. Jenkins melalui buku analisis deret waktu: *Forecasting and Control*. Untuk melihat adanya korelasi antar pengamatan, dapat dilakukan uji korelasinya yang sering dikenal dengan *autocorrelation function* (ACF). Tujuan deret waktu sendiri adalah untuk memahami dan menjelaskan mekanisme tertentu, meramalkan suatu nilai di masa depan, dan mengoptimalkan sistem kendali. Analisis deret waktu biasanya dijumpai dalam bidang ekonomi, industri, teknik dan ilmu-ilmu sosial (Makridakis dkk, 1998).

Deret waktu merupakan serangkaian pengamatan terhadap suatu variabel yang diambil secara berurutan berdasarkan pada interval waktu yang tetap, misalnya per jam, per hari, dan per bulan. Deret waktu adalah analisis yang mempelajari pola gerakan nilai-nilai variabel pada suatu interval waktu tersebut. Deret waktu memiliki kombinasi dari beberapa macam komponen, seperti *trend*, siklus (*cycle*), *seasonal* atau musiman, dan lainnya. *Trend* merupakan data yang menunjukkan arah secara kontinu yaitu bisa dalam keadaan naik atau turun. *Seasonal* merupakan sebuah pola pengulangan dengan periode yang diketahui, misalnya 12 bulan per tahun, 7 hari per minggu. *Cycle* adalah pola pengulangan yang teratur namun periodenya berubah-ubah, misalnya siklus bisnis. Deret waktu merupakan sekumpulan nilai yang berasal dari pengamatan terhadap variabel yang diamati secara berurutan dari waktu ke waktu dan antar pengamatan yang saling berkaitan. Pengambilan data dilakukan pada interval waktu dan sumber yang sama (Wei, 2006).

Analisis deret waktu adalah suatu metode prediksi untuk masa yang akan datang yang dilakukan berdasarkan data masa lalu dari suatu variabel dan *error*.

Tujuan dari metode prediksi deret waktu adalah untuk menemukan pola dari data deret waktu dan mengrapolasikan pola tersebut ke periode yang akan datang.

Setiap pengamatan yang dilakukan dapat dinyatakan dalam suatu bentuk variabel random Y_t yang didapatkan berdasarkan indeks waktu tertentu t_i dengan $i = 1, 2, \dots, n$ sebagai urutan waktu pengamatan, sehingga penulisan dari data deret waktu adalah $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$. Terdapat beberapa hal yang perlu diperhatikan dalam melakukan analisis data deret waktu antara lain yaitu stasioneritas data, fungsi autokorelasi, dan fungsi autokorelasi parsial.

A. Stasioneritas Data

Data stasioner jika :

$$F_{Y_{t_1}, \dots, Y_{t_n}}(x_1, \dots, x_n) = F_{Y_{t_1+k}, \dots, Y_{t_n+k}}(x_1, \dots, x_n) \quad (2.1)$$

Pada proses *strictly stasionary*, fungsi distribusi untuk setiap t adalah sama, sehingga fungsi rata-rata dan matriks autokovarians yang sama. Namun sangat sulit untuk memastikan fungsi distribusi secara tepat atau akurat, sehingga proses *weakly stasionary* (stasioner orde kedua) lebih sering dipakai. Fungsi rata-rata dari proses, didefinisikan pada Persamaan (2.2),

$$\mu_t = E(Y)_t \quad (2.2)$$

dan fungsi dari varians dari proses-proses yaitu pada Persamaan (2.3).

$$\sigma_t^2 = E(Y_t - \mu_t)^2 \quad (2.3)$$

Untuk menstasionerkan data terhadap varians digunakan transformasi Box-Cox. Rumus umum dalam mentransformasi Box-Cox yaitu terdapat pada Persamaan (2.4) sebagai berikut (Wei, 2006).

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda}, \text{ berlaku } \lambda \neq 0 \quad (2.4)$$

Untuk melihat $\lambda = 0$ sesuai dengan logaritmik transformasi, dapat dituliskan sebagai Persamaan (2.5).

$$\lim_{\lambda \rightarrow 0} T(Y_t) = \lim_{\lambda \rightarrow 0} \frac{Y_t^\lambda - 1}{\lambda} = \ln(Y_t) \quad (2.5)$$

λ adalah parameter transformasi dari transformasi Box-Cox. Tabel 2.1 terdapat beberapa nilai λ yang digunakan pada transformasi Box-Cox.

Tabel 2. 1 Transformasi Box Cox menunjukkan kriteria transformasi dari nilai lamda yang didapatkan.

Nilai Estimasi λ	Transformasi
-1	$1/Y_t$
-0,5	$1/\sqrt{Y_t}$
0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1	Y_t (tidak ada transformasi)

Tahapan selanjutnya yaitu melakukan identifikasi kestasioneran data terhadap rata-rata. Identifikasi kestasioneran terhadap rata-rata dapat dilakukan secara visual dengan menggunakan deret waktu *plot* dan plot ACF. Dikatakan stasioner terhadap rata-rata jika plot deret waktu berfluktuasi disekitar nilai rata-rata yang konstan. Apabila tidak stasioner terhadap rata-rata maka dilakukan *differencing*. Rumus *differencing* dapat ditulis seperti Persamaan (2.6) (Wei, 2006).

$$W_t = (1 - B)^d Y_t \quad (2.6)$$

Keterangan:

W_t : Data hasil *differencing*

Y_t : Data *deret waktu* pada waktu ke-t

d : Orde *differencing*

B. Fungsi Autokorelasi (ACF)

Fungsi autokorelasi berfungsi untuk melihat kestasioneran data terhadap rata-rata dan juga untuk menunjukkan hubungan linier yang terjadi diantara pengamatan Y_t dengan Y_{t+k} . Korelasi antara keduanya dinyatakan dalam Persamaan (2.7). (Wei, 2006).

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.7)$$

Nilai autokovarians antara Y_t dengan Y_{t+k} dirumuskan seperti pada Persamaan (2.8) berikut.

$$\gamma_k = Cov(Y_t, Y_{t+k}) = E(Y_t - \mu)(Y_{t+k} - \mu) \quad (2.8)$$

Keterangan :

γ_0 : $Var(Y_t) = Var(Y_{t+k})$

γ_k : Fungsi Autokovarians pada lag ke- k

ρ_k : Fungsi Autokorelasi (ACF) pada lag ke- k

C. Fungsi Autokorelasi Parsial (PACF)

PACF berfungsi untuk mengukur tingkat keeratan hubungan antara pengamatan Y_t dengan Y_{t+k} setelah dependensi linier dalam variabel $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k+1}$ dihilangkan, maka korelasinya dituliskan pada Persamaan (2.9) berikut.

$$Corr Y_t, Y_k | Y_{t+1}, Y_{t+2}, \dots, Y_{t+k+1} \quad (2.9)$$

Secara umum fungsi autokorelasi parsial dirumuskan pada Persamaan (2.10) sebagai berikut (Wei, 2006).

$$P_k = \frac{Cov[(Y_t - \hat{Y}_t), (Y_{t+k} - \hat{Y}_{t+k})]}{\sqrt{Var(Y_t - \hat{Y}_t)} \sqrt{Var(Y_{t+k} - \hat{Y}_{t+k})}} \quad (2.10)$$

Keterangan:

P_k : fungsi parsial autokorelasi

Y_t : nilai pada waktu ke- t

Y_{t+k} : nilai pada waktu ke- k

\hat{Y}_t : dugaan variabel Y pada waktu ke- t

\hat{Y}_{t+k} : dugaan variabel Y pada waktu ke- k

2.3 ARIMA (*Autoregressive Integrated Moving Average*)

ARIMA merupakan salah satu model deret waktu yang sangat banyak dipakai untuk memprediksi suatu permasalahan. ARIMA merupakan suatu metode prediksi yang memanfaatkan data di masa lalu dan sekarang melalui variabel dependen yang menghasilkan peramalan jangka pendek yang akurat. Metode ARIMA diperkenalkan oleh Box dan Gwilym Jenkins tahun 1976 yang merupakan musiman dari Box-Jenkins. ARIMA merupakan statistik yang cocok untuk meramalkan secara cepat, bersifat fleksibel, dan tingkat keakuratannya efektif sehingga tepat digunakan dalam peramalan jangka pendek dan hanya membutuhkan

data historis dalam peramalannya (Rianto & Yunis, 2021). ARIMA adalah model univariat yang merupakan gabungan dari model *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA), dan terbentuk ARIMA. Bentuk umum model *autoregressive* dengan order p atau AR (p) sebagai berikut:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t$$

Persamaan AR (p) menunjukkan bahwa suatu model pada pengamatan waktu ke-t merupakan kombinasi linier dari pengamatan sebelumnya $t - 1, t - 2, t - 3, \dots, t - p$.

Keterangan :

- Y_t : Variabel yang diprediksi
 $Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots, Y_{t-p}$: Variabel bebas yang merupakan lag dari variabel tidak bebas.
 $\phi_1, \phi_2, \phi_3, \dots, \phi_p$: Parameter *autoregressive*.
 e_t : Nilai kesalahan yang tidak dapat dijelaskan model.

Kemudian bentuk umum model MA dengan order q atau MA(q) sebagai berikut:

$$Y_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \theta_3 e_{t-3} - \dots - \theta_p e_{t-p}$$

Model *moving average* MA (q) persamaannya menyatakan bahwa suatu model pada pengamatan waktu ke-t dipengaruhi kesalahan pada masa lalu.

Keterangan :

- Y_t : Variabel yang diprediksi
 $\theta_1, \theta_2, \theta_3, \dots, \theta_p$: Parameter *moving average*
 $e_{t-1}, e_{t-2}, e_{t-3}, \dots, e_{t-p}$: Nilai kesalahan pada saat t
 e_t : Nilai kesalahan yang tidak dapat dijelaskan model.

Lalu pada model campuran yaitu ARMA dengan order p dan q atau ARMA(p,q) bentuk umumnya sebagai berikut :

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_p e_{t-p}$$

Terakhir terdapat model ARIMA dengan orde p,d,q atau ARIMA (p,d,q). Diketahui bahwa orde p menyatakan AR, orde d menyatakan hasil *differencing* dan orde q

menyatakan MA. Jika pada data yang dimiliki belum stasioner terhadap rata-rata maka dilakukan *differencing*, dinyatakan pada persamaan berikut:

$$\phi(B)(1-B)^d Y_t = \theta_0 + \theta_q(B)e_t$$

dengan,

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$$

$$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$$

2.4 Analisis Deret Waktu dengan Faktor Intervensi

Model intervensi merupakan suatu model deret waktu yang digunakan untuk melihat suatu kejadian atau peristiwa baik internal maupun eksternal. Kejadian-kejadian tersebut diperkirakan mempengaruhi variabel yang diprediksi. Suatu data deret waktu yang dipengaruhi oleh beberapa kejadian eksternal atau internal disebut intervensi. Intervensi akan mengakibatkan perubahan pola data pada satu waktu t . Bentuk umum dari model intervensi adalah sebagai berikut (Wei, 2006):

$$Y_t = \sum_{j=1}^k \frac{\omega_j(B)B^{b_j}}{\delta_j(B)} I_{jt} + \frac{\theta(B)}{\phi(B)} a_t$$

Keterangan :

Y_t : Variabel respon pada saat t

$\frac{\theta(B)}{\phi(B)} a_t$: Deret *noise* yang dapat ditentukan menggunakan model ARIMA

$\omega_s(B)$: $\omega_0 + \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s$ (s menunjukkan lamanya suatu intervensi berpengaruh pada data setelah b periode)

$\delta_r(B)$: $1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r$ (r pola efek intervensi yang terjadi setelah $b+s$ periode sejak kejadian intervensi pada waktu T).

Intervensi mempunyai 2 macam model yaitu model fungsi step dan model fungsi pulse. Fungsi step merupakan bentuk intervensi yang terjadi dalam rentang waktu yang cukup lama atau panjang. Bentuk intervensi step dinotasikan sebagai berikut:

$$I_t = S_t = \begin{cases} 0, & t < T \\ 1, & t \geq T \end{cases}$$

Sedangkan fungsi pulse merupakan bentuk intervensi yang terjadi dalam waktu yang cukup singkat atau pada waktu tertentu. Bentuk intervensi pulse dinotasikan sebagai berikut:

$$I_t = P_t = \begin{cases} 0, & t \neq T \\ 1, & t = T \end{cases}$$

2.5 Orde Intervensi

Plot residual ARIMA sebelum intervensi digunakan untuk menentukan orde model intervensi yaitu orde b, r dan s. Batas yang dipakai untuk menentukan garis signifikansi adalah $\pm 2\sigma$. Orde b merupakan waktu tunda hingga dapat intervensi mulai terjadi (waktu *delay*). Orde s adalah lamanya suatu intervensi berpengaruh pada data setelah b periode (banyaknya gelombang yang terjadi) dan orde r menunjukkan lag setelah b dan s periode pada saat membentuk pola yang jelas. Lebih lanjut penjelasan orde r dikelompokkan sebagai berikut (Wei, 2006):

1. Jika $r = 0$, pola residual tidak membentuk pola eksponensial atau pola gelombang sinus.
2. Jika $r = 1$, pola residual akan membentuk pola eksponensial.
3. Jika $r = 2$, pola residual akan membentuk pola gelombang sinus teredam.

2.6 Analisis Deret Waktu dengan Faktor Deteksi Outlier

Deteksi outlier merupakan data pengamatan yang tidak konsisten pada deret waktunya. Efek dari outlier ini dapat dihitung dengan menggunakan model intervensi jika waktu dan penyebab diketahui. Deteksi outlier pertama kali dikemukakan oleh Fox (1972) dan Wei (2006) yang memperkenalkan outlier tipe 1 yaitu *additive outliers* (AO) dan tipe 2 yaitu *innovation outliers* (IO). Pada data deret waktu, deteksi outlier ini perlu dilakukan agar karakteristik data deret waktu menjadi lebih baik sehingga bisa menghasilkan model dan juga prediksi yang lebih baik.

Ada dua macam jenis outlier yaitu sebagai berikut:

1. *Additive Outlier* (AO)

AO adalah tipe outlier yang terjadi pada efek data deret waktu hanya pada satu periode saja. Bentuk umum AO dalam proses ARMA adalah sebagai berikut:

$$\begin{aligned}
Y_t &= \begin{cases} X_t & t \neq T \\ X_t + \omega & t = T \end{cases} \\
&= X_t + \omega l_t^{(T)} \\
&= \frac{\theta(B)}{\phi(B)} a_t + \omega l_t^{(T)}
\end{aligned}$$

dengan,

$$I_t^{(T)} = \begin{cases} 1, & t = T \\ 0, & t \neq T \end{cases}$$

adalah variabel indikator untuk menjelaskan ada atau tidaknya outlier pada waktu ke T.

2. *Innovational Outliers (IO)*

IO merupakan tipe outlier yang terjadi pada efek data deret waktu mengikuti proses ARMA. Bentuk umum IO dalam proses ARMA adalah sebagai berikut :

$$Y_t = X_t + \frac{\theta(B)}{\phi(B)} \omega l_t^{(T)} = \frac{\theta(B)}{\phi(B)} (a_t + \omega l_t^{(T)})$$

Dari persamaan tersebut, dapat disimpulkan bahwa AO hanya mempengaruhi ke-T, sedangkan tipe outlier IO mempengaruhi suatu pengamatan Y_T, Y_{T+1}, \dots , melebihi waktu T sepanjang memori sistem yang dijelaskan oleh $\frac{\theta(B)}{\phi(B)}$. Secara umum, sebuah data deret waktu bisa saja memiliki beberapa outlier, misalnya sebuah n buah outlier dengan tipe yang berbeda. Bentuk umum dari outlier dapat ditulis sebagai berikut :

$$Y_t = \sum_{j=1}^n \omega_j v_j(B) l_t^{(T_j)} + X_t$$

$$X_t = \frac{\theta(B)}{\phi(B)} a_t, v_j(B) = 1 \text{ untuk AO, dan } v_j = \frac{\theta(B)}{\phi(B)} \text{ untuk IO pada waktu } t = T_j.$$

2.7 Pemilihan Model Terbaik

Untuk memilih model terbaik dapat dilakukan beberapa cara yaitu dengan cara:

1. AIC (*Akaike Info Criterion*)

AIC adalah suatu pendekatan untuk mendapatkan informasi mengenai kelayakan dalam estimasi modelnya atau spesifikasi modelnya. Nilai AIC yang kecil memberikan informasi bahwa model tersebut semakin baik. Adapun rumus AIC:

$$AIC = -2 \log(\text{maximum likelihood}) + 2k$$

Nilai k adalah jumlah parameter dalam model, serta pada nilai fungsi maximum likelihood terlibat juga (Cryer Chan, 2008).

2. MAPE (*Mean Absolut Percentage Error*)

Nilai MAPE menunjukkan tingkat akurasi suatu model berdasarkan perbandingan hasil prediksi model dengan data aktual. Nilai MAPE dapat dihitung dengan rumus sebagai berikut :

$$MAPE = \frac{1}{N} \frac{\sum_{i=1}^N |Y_i - \hat{Y}_i|}{|Y_i|} \times 100\%$$

Keterangan:

N : Banyaknya prediksi

Y_i : Nilai data aktual

\hat{Y}_i : Nilai data prediksi

Model yang terbaik dapat ditentukan berdasarkan nilai MAPE. Dengan kriteria pada Tabel 2.2:

Tabel 2. 2 Kriteria MAPE. Semakin kecil nilai MAPE yang didapatkan maka model semakin baik.

MAPE	Kriteria model dari prediksi
< 10%	Sangat baik
10% – 20%	Baik
20% – 50%	Buruk
> 50%	Sangat buruk