

BAB II

TINJAUAN PUSTAKA

2.1 Wisatawan Mancanegara

Menurut *United Nation World Tourism Organization* (UNWTO), wisatawan mancanegara adalah setiap orang yang berkunjung ke suatu negara di luar tempat tinggalnya untuk beberapa keperluan tanpa bermaksud memperoleh penghasilan di tempat yang dikunjungi dan lamanya kunjungan tersebut tidak lebih dari 12 bulan. Definisi ini mencakup dua kategori tamu mancanegara yaitu :

- a. Wisatawan (*tourist*) adalah setiap pengunjung yang datang ke suatu tempat dan tinggal di tempat tersebut tidak lebih dari dua belas 12 bulan dengan maksud kunjungan antara lain: berlibur, rekreasi dan olahraga bisnis, mengunjungi teman dan keluarga, misi, menghadiri pertemuan, konferensi, kunjungan dengan alasan kesehatan, belajar, dan keagamaan.
- b. Pelancong (*excursionist*) adalah setiap pengunjung seperti definisi di atas yang tinggal ditempat tersebut kurang dari dua puluh empat jam di tempat yang dikunjungi (termasuk *cruise passenger* yaitu setiap pengunjung yang tiba di suatu tempat dengan menggunakan kapal atau kereta api, dan mereka tidak menginap di akomodasi yang tersedia di negara tersebut) (BPS: Statistik Kunjungan Wisatawan Mancanegara, 2016).

Definisi wisatawan menurut Norval adalah setiap orang yang datang dari suatu negara yang alasannya bukan untuk menetap atau bekerja di situ

secara teratur dan yang di negara di mana ia tinggal untuk sementara itu membelanjakan uang yang didapatkannya di lain tempat, sedangkan menurut Soekadijo wisatawan adalah pe

ngunjung di negara yang dikunjunginya setidaknya-tidaknya tinggal dalam kurun waktu 24 jam dan datang berdasarkan motivasi sebagai berikut (Astuti, 2016).

- a. Mengisi waktu senggang atau untuk bersenang-senang, berlibur, untuk alasan kesehatan, studi, keluarga, dan sebagainya.
- b. Melakukan perjalanan untuk keperluan bisnis.
- c. Melakukan perjalanan untuk mengunjungi pertemuan-pertemuan atau sebagai utusan (ilmiah, *administrative*, *diplomatic*, keagamaan, olahraga dan sebagainya).
- d. Dalam rangka pelayaran pesiar, jika kalau ia tinggal kurang dari 24 jam.

2.2 Peramalan

Pada dasarnya peramalan merupakan suatu dugaan atau perkiraan atas terjadinya kejadian diwaktu mendatang. Menurut jangka waktunya, peramalan dibagi menjadi 3 periode sesuai dengan materi yang diramalkannya. Periode peramalan dibagi menjadi 3, yaitu:

1. Peramalan Jangka Panjang (*Long-Term Forecasting*)

Merupakan peramalan yang memperkirakan keadaan dalam waktu beberapa tahun ke depan.

2. Peramalan Jangka Menengah (*Mid-Term Forecasting*)

Merupakan peramalan dalam jangka waktu bulanan atau mingguan.

3. Peramalan Jangka Pendek (*Short-Term Forecasting*)

Merupakan peramalan dalam jangka waktu harian hingga setiap jam.

(Nasution, 2005)

2.3 Analisis *Time Series*

Analisis deret waktu diperkenalkan pada tahun 1970 oleh George E. P. Box dan Gwilym M. Jenkins melalui bukunya yang berjudul *Time Series Analysis: Forecasting and Control*. Sejak saat itu, deret waktu mulai banyak dikembangkan.

Deret waktu (*time series*) merupakan serangkaian data pengamatan yang terjadi berdasarkan indeks waktu secara berurutan dengan interval waktu secara berurutan dengan interval waktu tetap. Analisis deret waktu adalah salah satu prosedur statistika yang diterapkan untuk meramalkan struktur *probabilistic* keadaan yang akan terjadi di masa yang akan datang dalam pengambilan keputusan.

Suatu urutan pengamatan memiliki model deret waktu jika memenuhi dua hal berikut.

1. Interval waktu antar indeks waktu t dapat dinyatakan dalam satuan waktu yang sama (identik)
2. Adanya ketergantungan antara pengamatan Z_t dengan Z_{t+k} yang dipisahkan oleh jarak waktu berupa kelipatan Δ_t sebanyak k kali (dinyatakan sebagai lag k).

Pada peramalan data time series harus mempertimbangkan tipe atau pola data tersebut. Pola data dapat dibedakan menjadi empat yaitu *horizontal*, *trend*, musiman, dan siklis. Pola *horizontal* merupakan kejadian yang tidak terduga dan bersifat acak, tetapi kemunculannya dapat mempengaruhi fluktuasi data *time series*. Pola *trend* merupakan kecenderungan arah data dalam jangka panjang, dapat berupa kenaikan maupun penurunan. Pola musiman merupakan fluktuasi dari data yang terjadi secara periodik dalam kurun waktu satu tahun, seperti triwulan, kuartalan, bulanan, mingguan, atau harian. Sedangkan pola siklis merupakan fluktuasi dari data untuk waktu yang lebih dari satu tahun atau jangka panjang, seperti pada siklus ekonomi atau bisnis. Permodelan deret waktu juga memiliki ciri-ciri yaitu mengasumsikan bahwa data dalam keadaan stasioner. Deret waktu dikatakan stasioner jika tidak ada perubahan kecenderungan dalam rata-rata dan perubahan variansi.

Misalkan Z_t adalah suatu variable random, menurut Wei (1990), $\{Z_t\}$ dikatakan *strictly stationer* (*stasioner kuat*) jika:

1. $\mu_t = E(Z_t) = \mu$ (rata-rata konstan)
2. Jika $E(Z_t) < \infty$, maka $Var(Z_t) = E[(Z_t - \mu)^2] = \sigma^2$ (variansi konstan)
3. $Cov(Z_t, Z_{t-k}) = E[(Z_t - \mu)(Z_{t-k} - \mu)] = \gamma_k$ untuk setiap t dan k bilangan bulat.

Kondisi yang sering ditemukan dalam permodelan deret waktu adalah kondisi dimana rata-rata yang tidak stasioner. Salah satu cara yang dapat dilakukan untuk menstasionerkan data yang tidak stasioner dalam rata-rata yaitu dengan menggunakan metode *differencing* (pembedaan). Pembedaan ini dilakukan agar dapat mengatasi korelasi antara Z_t dengan Z_{t-k} , dengan k yang

cukup besar. Pada *short memory*, perbedaan dilakukan dengan hasil bernilai bilangan bulat, sedangkan pada *long memory*, perbedaan dilakukan dengan hasil bernilai bilangan pecahan.

2.3.1 Fungsi Autokorelasi (ACF)

Dalam menganalisis deret waktu yang diperlukan statistik kunci yaitu koefisien korelasi. Koefisien korelasi adalah hubungan suatu fungsi yang menunjukkan besarnya korelasi (hubungan linear) antara pengamatan pada waktu ke t (Z_t) dengan pengamatan waktu-waktu yang sebelumnya ($Z_{t-1}, Z_{t-2}, \dots, Z_{t-k}$).

Kovariansi antara Z_t dan Z_{t-k} adalah sebagai berikut

$$\gamma_k = \text{cov}(Z_t, Z_{t-k}) = E[(Z_t - \mu)(Z_{t-k} - \mu)] \quad (2.1)$$

Keterangan :

$$\begin{aligned} \gamma_k &= \text{Autokovariansi pada lag-}k \\ \text{cov}(Z_t, Z_{t-k}) &= \text{Nilai ekspektasi ACF} \\ \mu &= \text{Nilai konstanta Moving Average} \end{aligned}$$

Sedangkan autokorelasi antara Z_t dan Z_{t-k} adalah sebagai berikut

$$\rho_k = \frac{\text{cov}(Z_t, Z_{t-k})}{\sqrt{\text{var}(Z_t)}\sqrt{\text{var}(Z_{t-k})}} \quad (2.2)$$

dengan $\sqrt{\text{var}(Z_t)}\sqrt{\text{var}(Z_{t-k})} = \gamma_0$, sehingga diperoleh

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (2.3)$$

Syarat untuk proses yang stasioner yaitu, fungsi autokovarians (γ_k) dan fungsi autokorelasi ρ_k memenuhi asumsi :

1. $\gamma_k = \text{cov}(Z_t, Z_{t-k})$; $\rho_0 = 1$
2. $|\gamma_k| \leq \gamma_0$; $|\rho_k| \leq 1$
3. $\gamma_k = \gamma_{-k}$; $\rho_k = \rho_{-k}$ (Wei, 2016)

Pada analisis *time series*, γ_k disebut sebagai fungsi autokovarian dan ρ_k disebut fungsi autokorelasi yang merupakan ukuran keeratan antara Z_t dan (Z_{t-k}) dari proses yang sama dan hanya dipisahkan oleh selang waktu k . Fungsi autokorelasi dihitung sesuai dengan pengambilan data dan dirumuskan sebagai berikut:

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

Dimana $k = 0, 1, 2, \dots$ (2.4) (Wei, 2016)

Diagram ACF dapat digunakan sebagai alat untuk mengidentifikasi kestasioneran data. Jika diagram ACF cenderung turun lambat baik secara linear maupun hiperbolik, maka dapat disimpulkan data belum stasioner dalam rata-rata.

2.3.2 Fungsi Autokorelasi Parsial (PACF)

Dalam analisis regresi, apabila peubah tidak bebas Y diregresikan terhadap peubah-peubah bebas X_1 dan X_2 , akan timbul pertanyaan “sejauhmana peubah X_1 mampu menerangkan keadaan dari Y apabila mula-mula X_2 dipisahkan (*partialled out*)”. Ini berarti meregresikan Y atas X_1 dan menghitung kesalahan sisa (*residual errors*), kemudian meregresikan lagi nilai sisa tersebut atas X_2 . Dalam analisis deret waktu, konsep yang sama

juga berlaku. Autokorelasi parsial digunakan untuk mengukur tingkat keeratan (*association*) antara Z_t dan Z_{t-k} , apabila pengaruh dari lag waktu (time lag) 1, 2, 3, ..., $k-1$ dianggap terpisah. Fungsi autokorelasi parsial adalah suatu fungsi yang menunjukkan besarnya korelasi parsial antara pengamatan pada waktu ke t (Z_t) dengan pengamatan waktu-waktu yang sebelumnya ($Z_{t-1}, Z_{t-2}, \dots, Z_{t-k}$). Fungsi autokorelasi parsial (PACF) dapat dinyatakan sebagai berikut :

$$\phi_{kk} = \text{corr}(Z_t, Z_{t-k} \vee Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}) \quad (2.5)$$

Nilai PACF dapat dihitung menggunakan persamaan (2.5) sebagai berikut:

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j}$$

Dimana $\phi_{ij} = \phi_{ij} - \phi_{ii} \phi_{jj}$ (Wei, 2016)

2.4 Model *Autoregressive Fractionally Moving Average* (ARFIMA)

Model ARIMA digunakan untuk data *time series short memory* (jangka pendek), sebaliknya untuk data *time series* yang memiliki ketergantungan jangka panjang (*long memory*) yaitu jika diantara observasi dengan periode yang terpisah jauh masih mempunyai korelasi yang tinggi, model yang digunakan adalah ARFIMA. *Long memory* terlihat dari nilai autokorelasi turun lambat secara hiperbolik untuk *lag* yang semakin besar (Kusuma, 2009). Ini menyebabkan parameter d bernilai sangat kecil, sehingga Granger dan Joyeux memperkenalkan model ARFIMA. Model ARFIMA secara umum sama dengan model ARIMA pada persamaan (2.6), begitu juga

apabila model memiliki pola *seasonal* (SARFIMA) pun juga memiliki model yang sama dengan persamaan (2.7). perbedaan model ARIMA terletak pada parameter pembeda yang bernilai pecahan pada model ARFIMA.

$$\phi(B)(1-B)^d Z_t = \theta(B) a_t \quad (2.6)$$

Dimana

$\phi_p = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ adalah koefisien komponen AR non musiman dengan orde p

$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ adalah koefisien komponen MA non musiman dengan orde q

$(1-B)^d$ = differencing non musiman dengan orde d

B = operator *Backward*

ϕ = parameter model *autoregressive*

θ = parameter model *moving average*

d = nilai parameter pembedaan

Z_t = nilai data deret waktu ke- t

a_t = galat waktu ke- t (Wei, 2006)

Generalisasi dari model ARIMA untuk data yang memiliki pola musiman, model terbaik yaitu SARIMA $(p,d,q) (P,D,Q)^S$ dirumuskan oleh Wei (2006) sebagai berikut:

$$\phi_p(B) \Phi_P(B^S) (1-B)^d (1-B)^D Z_t = \theta_q(B) \Theta_Q(B^S) a_t \quad (2.7)$$

Keterangan:

p, d, q = orde AR, *differencing*, MA non musiman

P, D, Q = orde AR, *differencing*, MA musiman $S = 3, 4, 6, 1, 2$

$\Phi_p(B^S) = (1 - \Phi_1 B^S - \dots - \Phi_p B^{pS})$ = koefisien komponen AR musiman S dengan orde P

$\Theta_Q(B^S) = (1 - \Theta_1 B^S - \dots - \Theta_Q B^{QS})$ = koefisien komponen MA musiman S dengan orde Q

Keterangan:

$(1 - B)^D$ = *differencing* non musiman S dengan orde D

B = operator *Backward*

ϕ = parameter model *autoregressive*

d = ordo pembedaan non musiman

θ = parameter model *moving average*

Φ = parameter model *autoregressive* musiman

D = ordo pembedaan musiman

Θ = parameter model *moving average* musiman

s = periode musiman

Z_t = nilai data deret waktu ke- t



a_t = galat waktu ke- t

Model ARFIMA (p,d,q) yang dikembangkan oleh Granger dan Joyeux (1980) adalah sebagai berikut:

$$\phi(B)(1-B)^d(Z_t - \mu) = \theta(B)a_t \quad (2.8)$$

Keterangan :

$\phi(B)$ = polynomial $AR(p)$

$\theta(B)$ = polynomial $MA(q)$

d = nilai parameter pembeda

μ = rata-rata dari pengamatan

Z_t = nilai data deret waktu ke- t

a_t = galat waktu ke- t

$a_t \sim IIDN(0, \sigma_a^2)$

$$(1-B)^d = \sum_{k=0}^{\infty} \binom{d}{k} (-1)^k B^k = \delta \text{ operator pembeda pecahan}$$

Untuk nilai d yang bernilai pecahan, operator *differencing* fraksional $(1-B)^d$ didefinisikan sebagai berikut :

$$(1-B)^d = 1 + \sum_{k=1}^{\infty} \frac{\Gamma(-d+k)}{\Gamma(-d)k!} B^k \quad (2.9)$$

Jika persamaan $\lambda_k(d) = \frac{\Gamma(-d+k)}{\Gamma(-d)k!}$ Pada persamaan diatas dijabarkan untuk

berbagai nilai k maka:

$$\text{Untuk } k = 1, \text{ diperoleh } \frac{\Gamma(-d+1)}{\Gamma(-d)1!} = \frac{(-d)!}{(-d-1)!1!} = -d$$

$$\text{Untuk } k = 2, \text{ diperoleh } \frac{\Gamma(-d+2)}{\Gamma(-d)2!} = \frac{(-d+1)!}{(-d-1)!2!} = \frac{-d(1-d)}{2}$$

$$\text{Untuk } k = 3, \text{ diperoleh } \frac{\Gamma(-d+3)}{\Gamma(-d)3!} = \frac{(-d+2)!}{(-d-1)!3!} = \frac{-d(2-d)}{6}$$

Dan sterusnya, persamaan diatas dapat dituliskan kembali menjadi

$$(1-B)^d = 1 + \sum_{k=1}^{\infty} \lambda_k(d) B^k$$

Dengan

$$\lambda_0(d) = 1$$

$$\lambda_1(d) = -d$$

$$\lambda_2(d) = \frac{-1}{2} d(1-d)$$

$$\lambda_3(d) = \frac{-1}{6} d(1-d)(2-d) \text{ dan seterusnya}$$

Sehingga apabila dijabarkan untuk berbagai nilai k dapat dituliskan menjadi:

$$(1-B)^d = 1 - dB - \frac{1}{2} d(1-d)B^2 - \frac{1}{6} d(1-d)(2-d)B^3 - \dots \quad (2.10)$$

2.5 Model *Seasonal Autoregressive Fractionally Moving Average* (SARFIMA)

Model SARFIMA adalah model data deret waktu yang dapat memodelkan ketergantungan jangka panjang (*long memory*) yang bersifat musiman dari suatu deret waktu. Ada pun model *Seasonal ARFIMA* dikembangkan oleh Granger dan Joyeux (1980)

$$\phi_p(B)\Phi_p(B^s)(1-B)^d(1-B^s)^D(Z_t-\mu)=\theta(B)\Theta(B^s)a_t \quad (2.11)$$

Keterangan :

μ = rata-rata dari pengamatan

$\{a_t\}_{t \in Z}$ = proses *white noise* dengan mean dan variansi sama dengan nol.

$s \in N$ = periode musiman

$(1-B^s)^D$ = *differencing* musiman S dengan orde D

B = operator *Backward*, yang dapat didefinisikan sebagai berikut

$$B^{sk}(X_t) = X_{t-sk}$$

Jika $k=1$, maka $B^s(X_t) = X_{t-s}$

Sedangkan operator perbedaan musiman (∇_s) dapat didefinisikan sebagai berikut:

$$\nabla_s(X_t) = X_t - X_{t-s}$$

$$= X_t - B^s(X_t)$$

$$= (1-B^s)X_t$$

Sehingga diperoleh,

$$\nabla_s = (1-B^s)$$

Jadi, pembedaan musiman orde D, dapat dituliskan

$$\nabla_s^D = (1 - B^s)^D \quad (2.12)$$

Karakteristik yang harus dipenuhi dalam pemodelan *Seasonal* ARFIMA adalah membuktikan adanya sifat long memory pada data. Sifat long memory dapat dibuktikan dengan cara mendapatkan nilai hurst adalah sebagai berikut:

1.1 Menentukan rata-rata, adjusted mean dan simpangan baku dari deret waktu dengan persamaan sebagai berikut:

$$\bar{Z} = \frac{1}{T} \sum_{t=1}^T Z_t \quad (2.13)$$

$$Z_t^{adj} = Z_t - \bar{Z} \quad (2.14)$$

$$S_t = \sqrt{\frac{1}{T} \sum_{t=1}^T (Z_t - \bar{Z})^2} \text{ dengan } t = 1, 2, \dots, T$$

1.2 Menentukan deviasi kumulatif dan rentang dari deviasi kumulatifnya

$$Z_t^{\dot{i}} = \sum_{t=1}^T Z_t^{adj}, \text{ dengan } t = 1, 2, \dots, T$$

$$R_t = \text{Max}(Z_1, Z_2, \dots, Z_t^{\dot{i}}) - \text{Min}(Z_1^{\dot{i}}, Z_2^{\dot{i}}, \dots, Z_t^{\dot{i}}) \text{ dengan } t = 1, 2, \dots, T \quad (2.15)$$

1.3 Menentukan nilai eksponensial Hurst (H) melalui statistik R/S dari data deret waktu.

❖❖❖

2.6 Metode Geweke and Porter-Hudak (GPH)

Metode GPH pertama kali diusulkan oleh Geweke dan Porter-Hudak pada tahun 1983, dimana persamaan spektral ARFIMA dibentuk menjadi persamaan regresi spektral dengan log periodegram sebagai variabel tak bebasnya. Penaksiran parameter pembeda d pada Metode GPH dapat dilakukan secara langsung tanpa mengetahui nilai parameter p dan q terlebih dahulu.

Penaksiran parameter d dapat dilakukan dengan metode GPH. Langkah pertama yang harus dilakukan yaitu menentukan nilai frekuensi harmonik ω_j untuk tiap observasi.

$$\omega_j = (2\pi \cdot j/T) \text{ dengan } j = 1, 2, \dots, m$$

Bandwidth optimal m dibatasi sampai $m = g(T) = [T^{0.5}]$. Tahapan selanjutnya adalah menentukan nilai periodogram dengan metode GPH, yang bentuk periodegramnya ditentukan melalui persamaan:

$$I_z(\omega_j) = \frac{1}{2\pi} \hat{\gamma}_t$$

dimana $\omega_j \in (-\pi, \pi)$ dan $\gamma_t = \hat{\gamma}_t$ nilai autokovarians dari lag ke- t . Kemudian nilai dari logaritma natural periodogramnya dijadikan sebagai variabel respon Y_j untuk regresi spektral.

$$Y_j = \ln(I_j(\omega_j)) \quad (2.17)$$

Dan untuk variabel prediktor, persamaan adalah sebagai berikut:

$$X_j = \ln \left[\frac{1}{4 \sin^2(\omega_j/2)} \right] \quad (2.18)$$

Sehingga dengan persamaan regresi linier $Y_j = \beta_0 + \beta_1 X_j + a_j$ nilai taksiran parameter d dapat ditentukan dengan metode least square pada persamaan

$$\hat{\beta}_1 = \hat{d} = i$$

2.7 Kriteria Pemilihan Model Terbaik

Aikaïke pada tahun 1973 memperkenalkan suatu pemilihan model terbaik selain MSE. AIC digunakan untuk menemukan model yang dapat menjelaskan data dengan parameter bebas yang minimum. Model yang dipilih adalah model dengan nilai AIC terendah. Wei (1990) menjelaskan untuk menghitung AIC maka digunakan persamaan sebagai berikut:

$$AIC = n \ln \hat{\sigma}_n^2 + 2p$$

Keterangan :

n = banyak observasi

m = jumlah parameter yang ditaksir

$\hat{\sigma}_n^2 = \text{nilai variabel residual}$

Untuk peramalan pengambilan keputusannya menggunakan *Mean Absolute Percentage Error* (MAPE). MAPE merupakan perhitungan yang menunjukkan nilai absolut rata-rata perbedaan antara nilai aktual dan nilai prediksi. Hasil peramalan dikatakan semakin akurat jika nilai MAPE semakin kecil (Naufal, 2017).

Rumus MAPE secara umum sebagai berikut :

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{x_t + f_t}{x_t} \right|}{n} \times 100\%$$

Keterangan:

n = Jumlah Sampel

x_t = Nilai Akurasi Indeks pada periode ke-t

f_t = Nilai Prediksi Indeks pada periode ke-t

