

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pada era globalisasi saat ini, pariwisata menjadi salah satu sektor yang berkontribusi cukup besar pada setiap perkembangan serta pertumbuhan negara, termasuk Indonesia. Sektor pariwisata berperan sebagai salah satu sektor yang angka pertumbuhannya cukup signifikan, terutama terlihat dalam mendatangkan wisatawan mancanegara.

Indonesia merupakan sebuah negara yang sangat kaya akan sumber daya alam dan budaya, selain itu Indonesia terdiri dari 485 etnis yang beragam dengan lebih dari 300 bahasa. Hal tersebut menjadi salah satu faktor Indonesia menjadi salah satu destinasi yang menarik bagi wisatawan, terutama wisatawan mancanegara. Indonesia adalah salah satu negara yang memiliki daya saing cukup tinggi, itu sebabnya Indonesia memiliki rata-rata pertumbuhan wisatawan mancanegara yang baik.

Oleh karena itu, permasalahan tentang jumlah wisatawan mancanegara yang datang ke Indonesia menjadi hal yang penting. Dengan mengetahui prediksi jumlah wisatawan yang datang ke Indonesia di masa yang akan datang perusahaan pariwisata dapat mempersiapkan fasilitas-fasilitas untuk meningkatkan kepuasan para wisatawan tersebut.

Data jumlah wisatawan mancanegara yang datang ke Indonesia merupakan data runtun waktu (*time series*). Data *time series* adalah data yang dikumpulkan, dicatat, atau diamati berdasarkan urutan waktu. Data *time series*

tersebut dapat digunakan untuk membuat peramalan dan nantinya hasil peramalan dapat digunakan sebagai bahan pertimbangan dalam pengambilan kebijakan perusahaan pariwisata. Untuk menentukan metode peramalan pada data *time series* perlu diketahui pola dari data tersebut sehingga peramalan dengan metode yang sesuai dengan pola data dapat dilakukan. Pola data dapat dibedakan menjadi empat jenis, yaitu pola musiman, siklis, *trend*, dan *irregular*.

Berdasarkan data yang diperoleh, perkembangan jumlah wisatawan mancanegara yang datang ke Indonesia menunjukkan pola *trend* dan musiman karena plot data menunjukkan fluktuasi meningkat dari kiri bawah ke kanan atas dan mengandung pola yang berulang setiap tahunnya sehingga metode *Holt Winter* dan *Seasonal ARIMA* dapat digunakan untuk meramalkan jumlah wisatawan di masa yang akan datang. Seperti diketahui bahwa tidak ada metode peramalan yang dapat dengan tepat meramalkan keadaan data di masa yang akan datang. Oleh karena itu, setiap metode peramalan pasti menghasilkan kesalahan. Jika tingkat kesalahan yang dihasilkan semakin kecil, maka hasil peramalan akan semakin mendekati tepat. Alat ukur yang digunakan untuk menghitung kesalahan prediksi, antara lain *Mean Squared Deviation (MSD)*, *Mean Absolute Deviation (MAD)*, dan *Mean Absolute Percentage Error (MAPE)* [7].

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, maka dapat dirumuskan permasalahan sebagai berikut :

1. Bagaimana model peramalan perkembangan wisatawan mancanegara yang datang ke Indonesia dengan metode *Holt Winter* ?

2. Bagaimana model peramalan perkembangan wisatawan mancanegara yang datang ke Indonesia dengan metode *Seasonal ARIMA* ?
3. Bagaimana perbandingan hasil peramalan perkembangan wisatawan mancanegara yang datang ke Indonesia dengan menggunakan metode *Holt Winter* dan *Seasonal ARIMA* berdasarkan nilai *MAPE*, *MSD*, *MAD* ?

1.3 Pembatasan Masalah

Pada penulisan ini penulis hanya membatasi pada penerapan metode *Holt Winter* dan *Seasonal ARIMA*, serta perbandingan keduanya untuk peramalan perkembangan wisatawan mancanegara yang datang ke Indonesia dengan *Mean Squared Deviation (MSD)*, *Mean Absolute Percentage Error (MAPE)* serta *Mean Absolute Deviation (MAD)* sebagai pembandingnya.

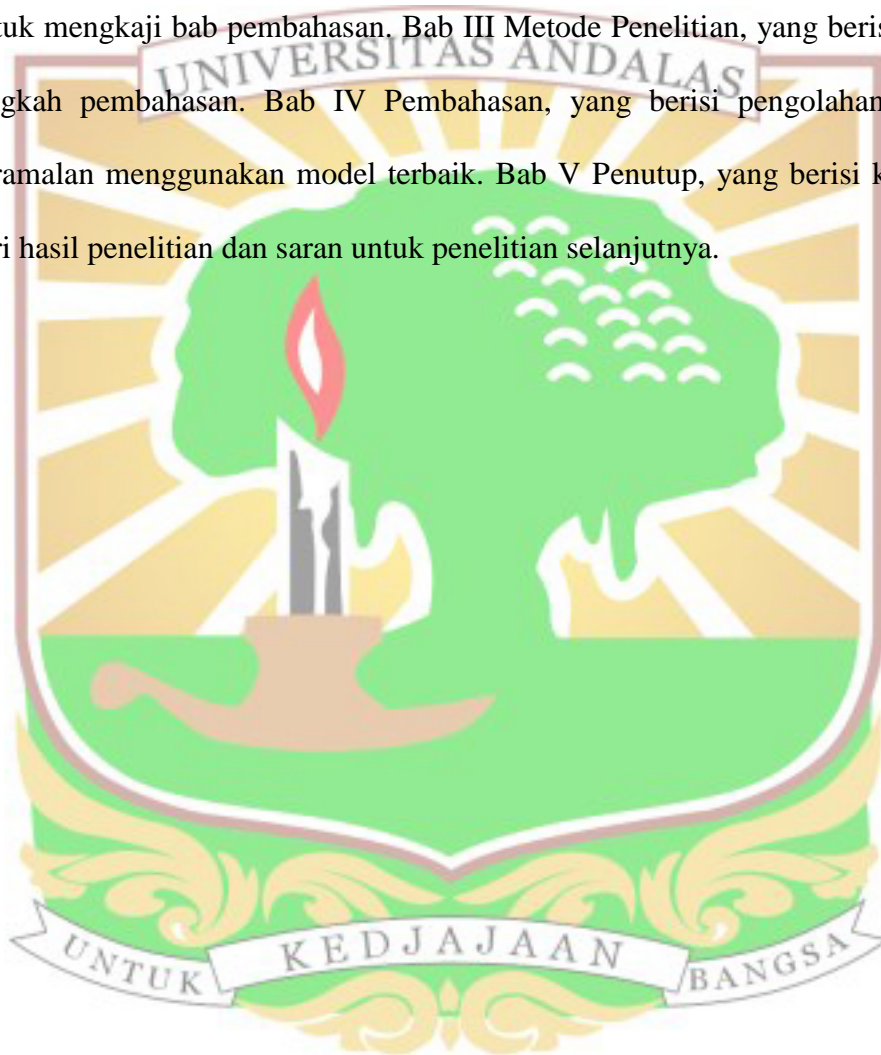
1.4 Tujuan Penulisan

Tujuan dari penulisan ini, antara lain:

1. Untuk mengetahui bagaimana model peramalan perkembangan wisatawan mancanegara yang datang ke Indonesia dengan metode *Holt Winter*.
2. Untuk mengetahui bagaimana model peramalan perkembangan wisatawan mancanegara yang datang ke Indonesia dengan metode *Seasonal ARIMA*.
3. Untuk mengetahui bagaimana perbandingan hasil peramalan perkembangan jumlah wisatawan mancanegara yang datang ke Indonesia dengan menggunakan metode *Holt Winter* dan *Seasonal ARIMA* berdasarkan nilai *MSD*, *MAD* serta *MAPE* .

1.5 Sistematika Penulisan

Adapun penulisan pada tugas akhir ini terdiri atas lima bab, yaitu Bab I Pendahuluan, yang berisi latar belakang, perumusan masalah, pembatasan masalah, tujuan penulisan dan sistematika penulisan. Bab II Landasan Teori, yang berisi uraian mengenai teori-teori serta definisi yang menjadi dasar perhitungan untuk mengkaji bab pembahasan. Bab III Metode Penelitian, yang berisi langkah-langkah pembahasan. Bab IV Pembahasan, yang berisi pengolahan data dan peramalan menggunakan model terbaik. Bab V Penutup, yang berisi kesimpulan dari hasil penelitian dan saran untuk penelitian selanjutnya.



BAB II

LANDASAN TEORI

2.1 Definisi Wisatawan Mancanegara

Berdasarkan rekomendasi *United Nation World Tourism Organization* (UNWTO) definisi wisatawan mancanegara adalah setiap orang yang melakukan perjalanan ke suatu negara di luar negara tempat tinggalnya, kurang dari satu tahun, didorong oleh suatu tujuan utama (bisnis, berlibur, atau tujuan pribadi lainnya), selain untuk bekerja dengan penduduk negara yang dikunjungi. Definisi ini mencakup dua kategori tamu mancanegara, yaitu [1]:

1. Wisatawan (*Tourist*) adalah setiap pengunjung seperti definisi di atas yang tinggal paling sedikit 24 jam, akan tetapi tidak lebih dari 12 bulan di tempat yang dikunjungi dengan maksud kunjungan antara lain :
 - a. Personal : berlibur, rekreasi, mengunjungi teman atau keluarga, belajar atau pelatihan, kesehatan olahraga, keagamaan, belanja, transit, dan lain-lain.
 - b. Bisnis dan profesional : menghadiri pertemuan, konferensi atau kongres, pameran dagang, konser, pertunjukan, dan lain-lain.
2. Pelancong (*Excursionist*) adalah setiap pengunjung seperti definisi di atas yang tinggal kurang dari dua puluh empat jam di tempat yang dikunjungi termasuk *cruise passanger* yaitu setiap pengunjung yang tiba di suatu negara dengan kapal atau kereta api, dimana mereka tidak menginap di akomodasi yang tersedia di negara tersebut.

2.2 Peramalan (*Forecasting*)

Peramalan (*forecasting*) adalah memperkirakan besarnya atau jumlah sesuatu pada waktu yang akan datang berdasarkan data pada masa lampau. Peramalan biasanya dilakukan untuk mengurangi ketidakpastian terhadap sesuatu yang akan terjadi di masa yang akan datang.

Dalam melakukan teknik peramalan ada beberapa kondisi untuk mendapatkan keputusan yang tepat. Berdasarkan kondisinya, peramalan dibedakan menjadi dua, yaitu [6] :

1. Peramalan Kualitatif

Peramalan yang dilakukan tanpa adanya data historis masa lalu untuk dijadikan dasar dalam peramalan. Hasil peramalan yang dibuat sangat tergantung pada pemikiran, pengalaman dan pengetahuan penyusun.

2. Peramalan Kuantitatif

Peramalan yang didasarkan atas data kuantitatif masa lalu yang diperoleh dari pengamatan nilai-nilai sebelumnya. Hasil peramalan yang dibuat tergantung pada metode peramalan yang digunakan. Penggunaan metode peramalan yang tepat akan menghasilkan peramalan yang baik.

Peramalan dengan metode kuantitatif dapat dibagi menjadi dua bagian, yaitu *time series model* dan *causal model*. *Time series model* didasarkan pada data yang dikumpulkan, dicatat, atau diamati berdasarkan urutan waktu dan peramalannya dilakukan berdasarkan pola tertentu dari data. Metode peramalan yang termasuk dalam *time series model*, antara lain *moving average*, *exponential smoothing*, dan Box–Jenkins (*ARIMA*). *Causal model* adalah model peramalan yang mempertimbangkan faktor-faktor yang bisa mempengaruhi jumlah yang

sedang diramalkan. Atau lebih mudahnya bahwa metode ini menggunakan pendekatan sebab-akibat, dan bertujuan untuk meramalkan keadaan di masa yang akan datang dengan menemukan dan mengukur beberapa variabel bebas yang penting beserta pengaruhnya terhadap variabel tidak bebas yang akan diramalkan.

Tahapan atau langkah-langkah untuk melakukan peramalan, antara lain :

1. Menentukan masalah yang akan dianalisis dan mengumpulkan data yang dibutuhkan dalam proses analisis tersebut.
2. Menyiapkan data sehingga data dapat diproses dengan benar.
3. Menetapkan metode peramalan yang sesuai dengan data yang telah disiapkan.
4. Menerapkan metode yang sudah ditetapkan dan melakukan prediksi pada data untuk beberapa waktu kedepan.
5. Mengevaluasi hasil peramalan.

2.3 Analisis *Time Series*

Time Series adalah suatu himpunan pengamatan X_t yang terjadi berdasarkan periode waktu tertentu. Periode waktu dapat berupa tahun, bulan, minggu, kuartal, serta hari atau jam. Metode *Time Series* adalah metode peramalan dengan menggunakan analisis pola hubungan antara variabel yang akan diperkirakan dengan variabel waktu. Peramalan data deret waktu (*time series*) mengacu pada tipe atau pola data secara umum.

Ada empat pola data yang menjadi dasar peramalan dengan model ini, yaitu [7] :

1. Pola musiman

Pola musiman merupakan fluktuasi dari data yang terjadi secara periodik dalam kurun waktu satu tahun, seperti triwulan, kuartalan, bulanan, mingguan, atau harian.

2. Pola Siklis

Pola siklis merupakan fluktuasi dari data untuk waktu yang lebih dari satu tahun.

3. Pola *trend*

Pola ini merupakan kecenderungan arah data dalam jangka panjang, dapat berupa kenaikan maupun penurunan.

4. *Irregular*

Pola *irregular* merupakan kejadian yang tidak terduga dan bersifat acak, tetapi kemunculannya dapat mempengaruhi fluktuasi data *time series*.

2.4 Stasioneritas

Stasioneritas berarti tidak terdapat perubahan yang drastis pada data. Fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan varian dari fluktuasi tersebut. Dalam pembentukan model deret waktu, data haruslah dalam keadaan stasioner [2].

2.4.1 Stasioner terhadap nilai tengah

Suatu data deret waktu dikatakan stasioner terhadap nilai tengah apabila data tersebut berfluktuasi di sekitar nilai tengah yang konstan. Data yang tidak stasioner terhadap nilai tengah dapat distasionerkan dengan melakukan *differencing* (pembedaan) dengan orde d , biasanya dilambangkan dengan ∇^d .

Operator shift mundur (*backward shift*) dapat digunakan untuk menggambarkan proses *differencing*. Misalkan notasi B merupakan operator shift mundur (*backward shift*) yang penggunaannya adalah $BX_t = X_{t-1}$. Dengan kata lain, notasi B yang dipasang pada X_t mempunyai pengaruh menggeser data 1 periode ke belakang. Dan dua penerapan B untuk shift akan menggeser data 2 periode ke belakang, yaitu $B(BX_t) = B^2X_t = X_{t-2}$.

Differencing untuk orde pertama adalah:

$$\nabla' X_t = X_t - X_{t-1} \quad (2.1)$$

Differencing orde pertama dari persamaan (2.1) dengan menggunakan operator shift mundur, dapat ditulis :

$$\nabla^1 X_t = X_t - BX_t = (1 - B)X_t$$

Apabila dalam *differencing* orde pertama data masih belum stasioner, maka dilakukan *differencing* orde kedua. Secara sistematis dapat ditulis:

$$\begin{aligned} \nabla^2 X_t &= \nabla' X_t - \nabla' X_{t-1} \\ &= (X_t - X_{t-1}) - (X_{t-1} - X_{t-2}) \\ &= X_t - 2X_{t-1} + X_{t-2} \end{aligned} \quad (2.2)$$

Differencing orde kedua dari persamaan (2.2) dengan menggunakan operator shift mundur, dapat ditulis sebagai berikut :

$$\begin{aligned} \nabla^2 X_t &= X_t - 2BX_t + B^2X_t \\ &= (1 - 2B + B^2) X_t \\ &= (1 - B)^2 X_t \end{aligned} \quad (2.3)$$

Secara umum jika terdapat *differencing* orde ke- d , maka dapat dinotasikan dengan :

$$\nabla^d X_t = (1 - B)^d X_t \quad (2.4)$$

Untuk menguji apakah data sudah stasioner terhadap nilai tengah maka dapat dilakukan Uji *Augmented Dickey-Fuller* (ADF) atau Uji Akar Unit.

Uji ADF merupakan salah satu uji formal untuk menguji kestasioneran data. Uji ini dikenalkan oleh David Dickey dan Whyne Fuller. Misalkan diduga suatu model mengandung akar unit dengan bentuk persamaan model sebagai berikut [7]:

$$X_t = \phi X_{t-1} + \varepsilon_t \quad (2.5)$$

Hipotesis yang digunakan untuk pengujian akar unit adalah:

$H_0 : \phi = 1$ (data mengandung akar unit / tidak stasioner)

$H_1 : \phi < 1$ (data tidak mengandung akar unit / stasioner)

Statistik uji *Augmented Dickey-Fuller* yang digunakan adalah:

$$ADF = \frac{\hat{\phi} - 1}{SE(\hat{\phi})}$$

dengan,

$$\hat{\phi} = \frac{\sum_{t=1}^n X_{t-1} X_t}{\sum_{t=1}^n X_{t-1}^2}$$

$$SE(\hat{\phi}) = \left[\hat{\sigma}^2 \left(\sum_{t=1}^n X_{t-1}^2 \right)^{-1} \right]^{1/2}$$

$$\hat{\sigma}^2 = \sum_{t=1}^n \frac{(X_t - \hat{\phi} X_{t-1})^2}{n - 1}$$

Kriteria pengambilan keputusan adalah tolak H_0 , jika statistik uji ADF lebih kecil dibandingkan nilai kritis tabel *Dickey-Fuller*.

2.4.2 Stasioner terhadap Ragam

Suatu data deret waktu dikatakan stasioner terhadap ragam jika ragam dari data tersebut konstan sepanjang waktu. Untuk menstabilkan ragam dapat dilakukan dengan menggunakan transformasi *Box-Cox*. Transformasi *Box-Cox* dilakukan dengan memilih dan menetapkan nilai dari parameter λ .

Secara umum, kita dapat menggunakan Transformasi pangkat sebagai berikut (Box and Cox 1964) :

$$T(X_t) = \frac{X_t^\lambda - 1}{\lambda}$$

Berikut beberapa nilai λ yang umum digunakan beserta bentuk transformasinya:

Tabel 2.4.2 Transformasi *Box-Cox*

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

2.5 Fungsi Autokorelasi (ACF) dan Fungsi Autokorelasi Parsial (PACF)

Fungsi autokovarian dan autokorelasi pada analisis time series dihasilkan dari kovarian dan korelasi antara X_t dan X_{t+h} pada proses yang sama dan terpisah pada interval h . Interval h disebut dengan lag [7].

Definisi 2.5.1 [2] Misalkan $\{X_t\}$ adalah deret waktu dengan $E(X_t^2) < \infty$, maka fungsi rata-rata $\{X_t\}$ adalah:

$$\mu(t) = E(X_t) \quad (2.6)$$

Kovarian antara X_t dan X_{t+h} , nilai dari periode waktu disebut dengan autokovarian di lag h . Kumpulan dari nilai γ_h , dimana $h= 1, 2, \dots$ disebut dengan fungsi autokovarian.

Definisi 2.5.2 [2] Misalkan $\{X_t\}$ adalah deret waktu stasioner maka fungsi autokovarian (ACVF) dari $\{X_t\}$ pada lag h adalah:

$$\gamma_h = Cov(X_{t+h}, X_t) = E[(X_{t+h} - \mu)(X_t - \mu)] \quad (2.7)$$

Fungsi autokorelasi (ACF) dari $\{X_t\}$ pada lag h adalah:

$$\rho_h = \frac{\gamma_h}{\gamma_0} = Corr(X_{t+h}, X_t) = \frac{cov(X_{t+h}, X_t)}{\sqrt{var(X_{t+h})}\sqrt{var(X_t)}} \quad (2.8)$$

dengan :

ρ_h = koefisien autokorelasi pada lag- h

γ_h = autokovarian antara X_t dan X_{t+h}

γ_0 = ragam X_t

Autokorelasi digunakan pada data *time series* untuk mengukur bagaimana nilai X_t saling berhubungan dengan nilai masa depan (X_{t+1}, X_{t+2}, \dots) atau sama untuk nilai masa lalu (X_{t-1}, X_{t-2}, \dots). Bentuk autokorelasi pada *time series* dapat digunakan untuk mengidentifikasi model ARIMA.

Fungsi autokorelasi suatu data biasanya tidak diketahui, sehingga diduga dengan menggunakan fungsi autokorelasi sampel. Maka fungsi autokorelasi untuk sampel X_1, X_2, \dots, X_n adalah:

$$\hat{\rho}_h = \frac{\hat{\gamma}_h}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-h} (X_t - \bar{X})(X_{t+h} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad (2.9)$$

dimana $\bar{X} = \sum_{t=1}^n \frac{X_t}{n}$ adalah rata-rata sampel dari deret.

Untuk mengetahui apakah koefisien autokorelasi signifikan atau tidak, perlu dilakukan uji koefisien autokorelasi dengan hipotesis [7]:

$H_0 : \rho_h = 0$ (koefisien autokorelasi tidak signifikan)

$H_1 : \rho_h \neq 0$ (koefisien autokorelasi signifikan)

Statistik uji yang digunakan adalah:

$$t = \frac{\hat{\rho}_h}{SE(\hat{\rho}_h)}$$

dimana $SE(\hat{\rho}_h) = \frac{1}{\sqrt{n}}$

Kriteria keputusan adalah tolak H_0 , jika nilai $|t_{hit}| > t_{\frac{\alpha}{2}, df}$ dengan derajat bebas $df = n - 1$, dengan n merupakan banyaknya data dan h adalah lag dari koefisien autokorelasi yang diuji.

Fungsi autokorelasi parsial (PACF) menunjukkan ukuran keeratan hubungan antara X_t dan X_{t+h} dengan mengabaikan pengaruh dari $X_{t+1}, X_{t+2}, \dots, X_{t+h-1}$.

Untuk mengetahui apakah koefisien autokorelasi parsial signifikan atau tidak, perlu dilakukan uji koefisien autokorelasi parsial dengan hipotesis [7] :

$H_0 : \phi_h = 0$ (koefisien autokorelasi parsial tidak signifikan)

$H_1 : \phi_h \neq 0$ (koefisien autokorelasi parsial signifikan)

Statistik uji yang digunakan adalah:

$$t = \frac{\phi_h}{SE(\alpha_h)}$$

dimana $SE(\phi_h) = \frac{1}{\sqrt{n}}$

Kriteria keputusan, tolak H_0 jika nilai $|t_{hit}| > t_{\frac{\alpha}{2}, df}$ dengan derajat bebas $df = n - 1$, dengan n merupakan banyaknya data dan h adalah lag koefisien autokorelasi parsial yang diuji.

2.6 Proses *White Noise*

Suatu proses disebut proses *white noise* jika terdapat sebuah barisan variabel random $\{X_t\}$ yang tidak berkorelasi dengan rata-rata konstan $E(X_t) = \mu_0 = 0$, variansi konstan $Var(X_t) = \sigma^2$ dan $\gamma_h = Cov(X_t, X_{t+h}) = 0$ untuk $h \neq 0$ [7].

Fungsi autokovarians $\{X_t\}$ pada lag h adalah :

$$\gamma_h = \begin{cases} \sigma^2 & , \text{jika } h = 0 \\ 0 & , \text{jika } h \neq 0 \end{cases}$$

Fungsi autokorelasi

$$\rho_h = \begin{cases} 1, & h = 0 \\ 0, & h \neq 0 \end{cases}$$

Dasar dari proses *white noise* adalah nilai fungsi autokorelasi dari residu mendekati nol.

Untuk mengetahui apakah residu memenuhi proses *white noise* atau tidak, perlu dilakukan uji, salah satunya dengan Uji Ljung-Box. Pengujian dapat dilakukan dengan statistik uji :

$$Q = n(n+2) \sum_{h=1}^K \frac{\rho_h^2}{n-h}$$

dimana :

n = banyaknya observasi dalam runtun waktu

K = Banyaknya lag yang diuji

ρ_h = nilai koefisien autokorelasi pada lag- h

dengan hipotesis:

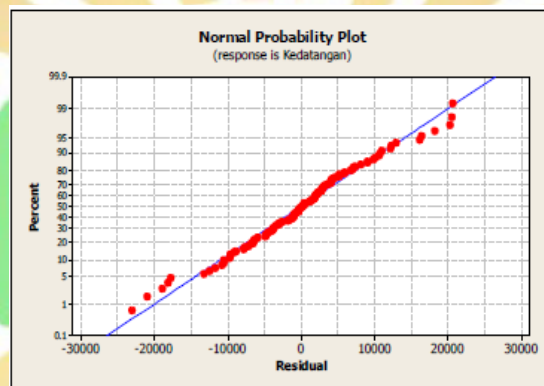
$H_0 : \rho_1 = \dots = \rho_h = 0$ (residu memenuhi proses *white noise*)

$H_1 : \exists \rho_i \neq 0$, untuk $i=1,2,\dots,h$ (residu tidak memenuhi proses *white noise*).

Kriteria keputusan H_0 ditolak jika $Q > \chi^2_{\alpha, K-p-q}$ dengan p dan q adalah orde dari ARMA (p,q) atau p-value lebih kecil dari taraf uji α 5%. Residu memenuhi proses *white noise* jika pada grafik ACF dari residu tidak ada lag (bar) yang melebihi garis batas signifikansi .

2.7 Uji Normalitas Residu

Untuk mengetahui apakah residu berdistribusi normal atau tidak maka dilakukan uji normalitas residu. Pengujian dapat dilakukan dengan analisis grafik *normal probability plot*. Jika residu berdistribusi normal, maka residu akan berada disekitar garis diagonal, seperti pada Gambar 2.7. Sebaliknya, jika residu tidak berdistribusi normal, maka residu akan menyebar dan berada jauh dari garis diagonal.



Gambar 2.7 Contoh grafik *normal probability plot* untuk residu berdistribusi normal

Pengujian kenormalan dapat dilakukan dengan menggunakan Kolmogorov-Smirnov.

Hipotesa :

H_0 : residu berdistribusi normal

H_1 : residu tidak berdistribusi normal.

Statistik Uji : $D_{hit} = \sup_x |S(x) - F_0(x)|$

dengan :

$F_0(x)$: fungsi yang dihipotesiskan yaitu berdistribusi normal

$S(x)$: fungsi distribusi kumulatif dari data asli

n : banyak residual

$D_{\alpha,n}$ didapatkan dari tabel Kolmogorov Smirnov, dengan $\alpha = 5\%$.

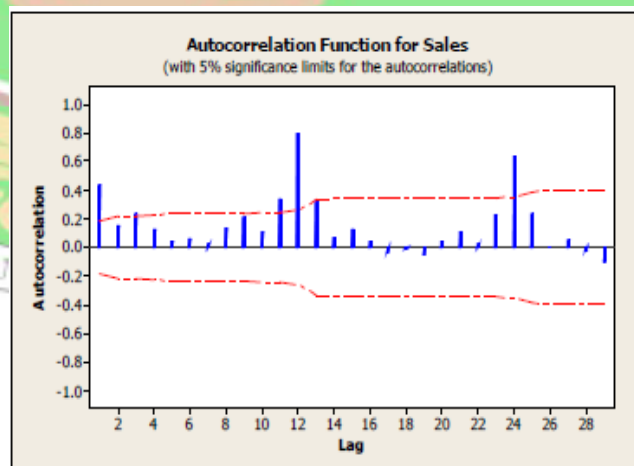
Kriteria pengujian :

Jika $D_{hit} > D_{\alpha,n}$ maka H_0 ditolak, yang artinya residual tidak berdistribusi normal.

2.8 Seasonalitas (Musiman)

Pola musiman merupakan pola yang berulang-ulang dalam selang waktu yang tetap dan umumnya tidak lebih dari satu tahun. Apabila dalam data hanya terdapat pola musiman, adanya faktor musim dapat dilihat dari grafik fungsi autokorelasinya atau dari perbedaan *lag* autokorelasinya.

Jika data dipengaruhi pola musiman, maka koefisien autokorelasi pada *lag* musiman berbeda nyata dari nol (bar melebihi garis putus-putus), seperti pada Gambar 2.8



Gambar 2.8 Contoh grafik fungsi autokorelasi untuk data yang dipengaruhi pola musiman bulanan

2.9 Metode *Smoothing*

Metode rata-rata tidak dapat digunakan untuk menggambarkan suatu data runtun waktu yang mengandung pola *trend*, pola musiman, atau mengandung pola *trend* dan musiman sekaligus. Peramalan pada data tersebut dapat dilakukan dengan metode *smoothing*. *Smoothing* adalah mengambil rata-rata dari nilai-nilai pada beberapa tahun untuk menaksir nilai pada suatu tahun. Metode *smoothing* diklasifikasikan menjadi dua kelompok, yaitu metode perataan dan metode pemulusan eksponensial (*exponential smoothing*) [5].

Metode perataan merupakan pembobotan yang sama terhadap nilai-nilai observasi. Apabila data dipengaruhi oleh pola *trend* maupun musiman, metode perataan tidak dapat digunakan untuk peramalan. Peramalan pada data yang dipengaruhi pola *trend* maupun musiman dilakukan dengan menggunakan metode *exponential smoothing*. Metode *exponential smoothing* menggunakan bobot yang berbeda untuk data masa lalu dan bobot tersebut mempunyai ciri menurun secara eksponensial. Metode dalam kelompok ini memerlukan adanya penentuan parameter tertentu seperti α , β serta γ dan nilai dari parameter terletak antara 0 dan 1.

2.10 Metode *Holt Winter*

Data pada *time series* bisa dipengaruhi oleh pola *trend* dan pola musiman. Jika data hanya dipengaruhi oleh pola *trend* maka metode yang digunakan adalah metode *Holt*. Dan jika data hanya dipengaruhi oleh pola musiman maka metode yang digunakan adalah metode *Winter*. Namun, jika data dipengaruhi pola *trend* sekaligus pola musiman, maka metode yang digunakan adalah metode *Holt-*

Winter. Metode *Holt-Winter* didasarkan pada tiga persamaan pemulusan, yakni persamaan pemulusan keseluruhan, pemulusan *trend*, dan persamaan pemulusan musiman. Metode ini dibagi menjadi dua model, yaitu model aditif dan multiplikatif. Perhitungan dengan model aditif dilakukan jika plot data asli menunjukkan fluktuasi musim yang relatif stabil, sedangkan model multiplikatif digunakan jika plot data asli menunjukkan fluktuasi musim yang bervariasi.

Adapun persamaan-persamaan yang digunakan dalam model aditif, yaitu:

1. Pemulusan eksponensial data asli

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

2. Pemulusan pola *trend*

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$

3. Pemulusan pola musiman

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$$

4. Ramalan p periode ke depan

$$\hat{Y}_{t+p} = L_t + pT_t + S_{t-s+p}$$

Dan adapun persamaan yang digunakan dalam model multiplikatif, yaitu:

1. Pemulusan eksponensial data asli

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1})$$

2. Pemulusan pola *trend*

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$

3. Pemulusan pola musiman

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s}$$

4. Ramalan p periode ke depan

$$\hat{Y}_{t+p} = (L_t + pT_t)S_{t-s+p}$$

dimana :

L_t = nilai pemulusan eksponensial pada waktu t

Y_t = data observasi pada waktu ke t

T_t = nilai pemulusan *trend* pada waktu t

α = konstanta pemulusan untuk data asli $0 < \alpha < 1$

β = konstanta pemulusan untuk pola *trend* $0 < \beta < 1$

γ = konstanta pemulusan untuk pola musiman $0 < \gamma < 1$

S_t = nilai pemulusan musiman pada waktu t

s = periode musiman

\hat{Y}_{t+p} = nilai peramalan untuk p periode ke depan

p = jumlah periode ke depan yang akan diramalkan

2.11 Metode *Seasonal ARIMA*

Untuk menyelesaikan *time series* musiman dapat digunakan metode *Seasonal Autoregressive Integrated Moving Average (SARIMA)*. Metode ini terdiri dari dua bagian, yaitu bagian tidak musiman dan bagian musiman. Bagian tidak musiman dari metode ini adalah model *ARIMA*.

2.11.1 Model *Autoregressive* (AR)

Model *Autoregressive* (AR) adalah model yang menunjukkan bahwa nilai amatan pada waktu t , X_t dipengaruhi oleh nilai amatan p waktu-waktu sebelumnya $X_{t-1}, X_{t-2}, \dots, X_{t-p}$. [2] :

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t \quad (2.10)$$

dimana :

X_t = data pada periode t , $t = 1, 2, \dots, n$

ϕ_i = parameter *Autoregressive* ke- i , $i = 1, 2, \dots, p$

p = orde dari model *Autoregressive* (AR)

ε_t = galat pada periode t , $t = 1, 2, \dots, n$

Persamaan (2.10) bila menggunakan operator shift mundur, dapat ditulis menjadi :

$$X_t = \phi_1 B X_t + \phi_2 B^2 X_t + \dots + \phi_p B^p X_t + \varepsilon_t$$

$$X_t - \phi_1 B X_t - \phi_2 B^2 X_t - \dots - \phi_p B^p X_t = \varepsilon_t$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) X_t = \varepsilon_t$$

$$\Phi_p(B) X_t = \varepsilon_t$$

Dengan $\Phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$.

2.11.2 Model *Moving Average* (MA)

Model *Moving Average* (MA) menunjukkan pengamatan pada waktu t , X_t dipengaruhi oleh galat dari pengamatan sebelumnya. Bentuk umum dari model MA(q) adalah [2]:

$$X_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.11)$$

dimana :

X_t = data pada periode t, t = 1,2,..., n

θ_i = parameter *moving average* ke-i, i = 1,2,...,q

q= orde dari model *moving average* (MA)

ε_t = galat pada periode t

Persamaan (2.11) dengan menggunakan operator shift mundur, dapat ditulis menjadi:

$$X_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

$$X_t = \varepsilon_t - \theta_1 B \varepsilon_t - \theta_2 B^2 \varepsilon_t - \dots - \theta_q B^q \varepsilon_t$$

$$X_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t$$

$$X_t = \Theta_q(B) \varepsilon_t$$

dengan $\Theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$.

2.11.3 Model Autoregressive Moving Average (ARMA)

Gabungan antara model AR(p) dengan MA(q) membentuk suatu model yang dinamakan dengan model ARMA, dimana p dan q adalah orde dari model ARMA yang dinotasikan dengan ARMA(p,q). Bentuk umum dari model ARMA(p,q) adalah [2]:

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_q \varepsilon_{t-q}$$

$$X_t - \phi_1 X_{t-1} - \dots - \phi_p X_{t-p} = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (2.12)$$

dimana:

X_t = data pada periode t, t=1,2,..., n

ϕ_i = parameter *Autoregressive* ke-i, i=1,2,..., p

θ_i = parameter *Moving Average* ke-i, i=1,2,..., q

ε_t = galat pada periode t

Persamaan (2.12) dengan menggunakan operator shift mundur, dapat ditulis menjadi:

$$\begin{aligned}
 X_t - \phi_1 B X_t - \dots - \phi_p B^p X_t &= \varepsilon_t - \theta_1 B \varepsilon_t - \dots - \theta_q B^q \varepsilon_t \\
 (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) X_t &= (1 - \theta_1 B - \theta_2 B^2 \dots - \theta_q B^q) \varepsilon_t \\
 \Phi_p(B) X_t &= \Theta_q(B) \varepsilon_t
 \end{aligned} \tag{2.13}$$

2.11.4 Model *Autoregressive Integrated Moving Average* (ARIMA)

Model ARIMA(p,d,q) merupakan gabungan dari model AR(p) dan MA(q), yaitu ARMA(p,q) dengan *differencing*. Berdasarkan persamaan (2.10) diperoleh bentuk umum dari model ARIMA(p,d,q) sebagai berikut [2]:

$$\begin{aligned}
 \Phi_p(B) X_t &= \Theta_q(B) \varepsilon_t \\
 \Phi_p(B) \nabla^d X_t &= \Theta_q(B) \varepsilon_t
 \end{aligned} \tag{2.14}$$

dimana:

Φ_p = koefisien AR orde dengan p

Θ_q = koefisien MA orde dengan q

∇^d = *differencing* dengan orde d

2.11.5 Model Seasonal Autoregressive Integrated Moving Average (SARIMA)

Model SARIMA ini merupakan model ARIMA yang mengandung unsur musiman. Model ARIMA terdiri dari bagian tidak musiman dan musiman. Bentuk persamaan model ARIMA dengan *differencing* non musiman adalah:

$$\Phi_p(B)(1-B)^d X_t = \Theta_q(B)\varepsilon_t \quad (2.15)$$

Dan model ARIMA dengan *differencing* musiman adalah:

$$\Phi_p^*(B^S)(1-B^S)^D X_t = \Theta_Q^*(B^S)\varepsilon_t \quad (2.16)$$

dimana :

$$\Phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 \dots - \phi_p B^p$$

$$\Theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 \dots - \theta_q B^q$$

$$\Phi_p^*(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{2S} \dots - \Phi_p B^{pS}$$

$$\Theta_Q^*(B^S) = 1 - \Theta_1 B^S - \Theta_2 B^{2S} \dots - \Theta_Q B^{QS}$$

Berdasarkan persamaan (2.15) dan (2.16) diperoleh bentuk persamaan model SARIMA(p,d,q)(P,D,Q)S sebagai berikut [5]:

$$\Phi_p(B)\Phi_p^*(B^S)(1-B)^d(1-B^S)^D X_t = \Theta_q(B)\Theta_Q^*(B^S)\varepsilon_t$$

dimana:

Φ_p = parameter *autoregressive* (AR) orde p

Θ_q = parameter *moving average* (MA) orde q

Φ_p^* = parameter *seasonal autoregressive* (SAR) orde P

Θ_Q^* = parameter *seasonal moving average* (SMA) orde Q

$(1 - B)^d = \text{differencing non musiman orde } d$

$(1 - B^S)^D = \text{differencing musiman orde } D$

$s = \text{panjang periode musiman}$

$p, q = \text{orde nonmusiman AR dan MA}$

$P, Q = \text{orde musiman AR (SAR) dan musiman MA (SMA)}$

Proses pemilihan model yang tepat dapat dilakukan dengan mengidentifikasi orde AR dan MA pada grafik ACF dan PACF.

Tabel 2.11.5.1. Pola ACF dan PACF Tidak Musiman

No	Model	ACF	PACF
1	AR (p)	Dies down (menurun secara eksponensial)	Cut off (terputus) setelah lag p
2	MA (q)	Cut off (terputus) setelah lag q	Dies down (menurun secara eksponensial)
3	ARMA (p,q)	Dies down (menurun secara eksponensial) setelah lag (q-p)	Dies down (menurun secara eksponensial) setelah lag (p-q)

Tabel 2.11.5.2. Pola ACF dan PACF Musiman dengan s Periode Per Musiman

No	Model	ACF	PACF
1	AR(p)	Dies down (menurun secara eksponensial) pada lag musiman	Cut off (terputus) setelah lag P_s
2	MA(q)	Cut off (terputus) setelah lag Q_s	Dies down (menurun secara eksponensial) pada lag musiman
3	ARMA(p,q)	Dies down (menurun secara eksponensial) pada lag musiman	Dies down (turun cepat secara eksponensial) pada lag musiman

2.12 Ketepatan Penggunaan Metode Peramalan

Penggunaan metode peramalan tergantung pada pola data yang akan dianalisis. Jika metode yang digunakan sudah dianggap benar untuk melakukan peramalan, maka pemilihan metode peramalan terbaik didasarkan pada tingkat kesalahan prediksi. Seperti diketahui bahwa tidak ada metode peramalan yang dapat dengan tepat meramalkan keadaan data di masa yang akan datang. Oleh karena itu, setiap metode peramalan pasti menghasilkan kesalahan. Jika tingkat kesalahan yang dihasilkan semakin kecil, maka hasil peramalan akan semakin mendekati tepat. Alat ukur yang digunakan untuk menghitung kesalahan prediksi, antara lain:

1. Mean Squared Deviation (MSD)

Metode ini dihitung dengan mengkuadratkan sisa atau kesalahan. Kemudian dijumlahkan dan dibagi dengan jumlah observasi. Pendekatan ini menghasilkan peramalan yang besar karena kesalahan-kesalahan tersebut dikuadratkan. Nilai *MSD* dapat di hitung dengan rumus sebagai berikut:

$$MSD = \frac{1}{n} \sum_{t=1}^n (X_t - \hat{X}_t)^2$$

2. Mean Absolute Deviation (MAD)

Metode ini digunakan untuk mengevaluasi metode peramalan menggunakan jumlah dari kesalahan-kesalahan yang absolut. *MAD* mengukur ketepatan ramalan dengan merata-rata kesalahan dugaan (nilai absolut masing-masing kesalahan). Nilai *MAD* dapat di hitung dengan rumus sebagai berikut:

$$MAD = \frac{1}{n} \sum_{t=1}^n |X_t - \hat{X}_t|$$

3. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian merata-ratakan kesalahan persentase absolut tersebut. Suatu model mempunyai kinerja yang sangat bagus jika nilai *MAPE* berada di bawah 10 %. Nilai *MAPE* dapat di hitung dengan rumus sebagai berikut:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{X_t - \hat{X}_t}{X_t} \right|$$

dengan

n = banyaknya data

X_t = data aktual pada waktu t

\hat{X}_t = data hasil peramalan pada waktu t

Semakin kecil nilai yang dihasilkan oleh ketiga alat ukur tersebut, maka metode peramalan yang digunakan akan semakin baik [7].



BAB III

METODE PENELITIAN

Bab ini berisi kajian tentang sumber data, metode analisis data yang berisi langkah-langkah peramalan perkembangan wisatawan mancanegara yang datang ke Indonesia dengan menggunakan model *Holt Winter* dan *Seasonal Autoregressive Integrated Moving Average (SARIMA)*.

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari situs resmi Kementerian Pariwisata (Kemenpar) yaitu data perkembangan wisatawan mancanegara yang datang ke Indonesia [4].

3.2 Metode Analisis Data

Adapun langkah-langkah peramalan dengan model *Holt Winter* dan *Seasonal Autoregressive Integrated Moving Average (SARIMA)* adalah sebagai berikut:

a. Metode *Holt Winter*

1. Membuat plot dan melihat apakah data terdapat unsur musiman.
2. Menentukan nilai parameter α , β dan γ .
3. Melakukan pemulusan eksponensial Winter.
4. Memilih model terbaik dengan melihat nilai *MSD*, *MAD* serta *MAPE* terkecil.
5. Melakukan peramalan.

b. Metode *Seasonal Autoregressive Integrated Moving Average (SARIMA)*

1. Membuat plot dan melihat apakah ada indikasi data musiman serta data sudah stasioner atau belum.
2. Mengidentifikasi model dengan cara melihat korelogram ACF dan PACF.
3. Penaksiran dan pendugaan parameter.
4. Pemilihan model terbaik dengan melihat nilai *MSD*, *MAD* serta *MAPE* terkecil.
5. Melakukan Peramalan.

c. Membandingkan hasil peramalan metode Holt Winter dengan *Seasonal ARIMA* berdasarkan nilai *MSD*, *MAD* serta *MAPE* terkecil.



4.1 Metode Holt Winter


Metode Holt Winter digunakan jika data dipengaruhi pola *trend* dan pola musiman sekaligus. Bentuk *time series plot* pada gambar 1 memperlihatkan bahwa fluktuasi musim yang bervariasi. Hal ini menunjukkan bahwa data multiplikatif. Kemudian dicari konstanta pemulusan untuk data asli (α), konstanta pemulusan untuk pola trend (β), dan konstanta pemulusan untuk pola musiman (γ) dengan menggunakan bantuan software minitab. Konstanta pemulusan tersebut terletak antara 0 dan 1 yang dicari dengan cara *trial and error*. Pemilihan konstanta pemulusan terbaik berdasarkan nilai eror atau nilai *MAPE*, *MAD* serta *MSD* yang paling kecil. Berikut beberapa kemungkinan konstanta pemulusan α , β , γ .

Tabel 4.1.1 Pendugaan konstanta pemulusan

No.	Konstanta pemulusan	<i>MAPE</i>	<i>MAD</i>	<i>MSD</i>
1	$\alpha = 0,1$ $\beta = 0,1$ $\gamma = 0,1$	4,29	28,80	1193,37
2	$\alpha = 0,1$ $\beta = 0,1$ $\gamma = 0,2$	4,33	29,15	1226,78
3	$\alpha = 0,2$ $\beta = 0,3$ $\gamma = 0,1$	4,23	28,64	1201,46
4	$\alpha = 0,2$ $\beta = 0,1$ $\gamma = 0,1$	3,97	26,84	1088,63
5	$\alpha = 0,2$ $\beta = 0,2$ $\gamma = 0,2$	4,21	28,52	1188,40
6	$\alpha = 0,3$ $\beta = 0,2$ $\gamma = 0,1$	4,06	27,49	1117,83
7	$\alpha = 0,3$ $\beta = 0,1$ $\gamma = 0,2$	4,08	27,67	1106,45
8	$\alpha = 0,4$ $\beta = 0,1$	3,97	27,01	1098,06


	$\gamma = 0,1$			
9	$\alpha = 0,3$ $\beta = 0,3$ $\gamma = 0,1$	4,13	27,96	1156,39

Berdasarkan Tabel 4.1.1 di atas, nilai *MAPE*, *MSD*, serta *MAD* yang paling kecil diperoleh pada kombinasi α , β dan γ yaitu 0,2, 0,1 dan 0,1, yang menghasilkan eror atau nilai *MAPE* sebesar 3,97% , nilai *MSD* sebesar 1088,63 serta nilai *MAD* sebesar 26,84. Hasil dari pemulusan ini dapat dilihat pada Lampiran 1. Berikut ditampilkan plot perkembangan wisatawan mancanegara dengan menggunakan metode Holt-Winter dengan α , β dan γ terbaik.




Gambar 2. Plot metode Holt-Winter dari perkembangan jumlah wisatawan

Selanjutnya diperiksa apakah residual bersifat *white noise* dan berdistribusi normal. Bersifat *white noise* berarti tidak terdapat korelasi antar residual. Berikut korelogram ACF dan PACF dari residual.

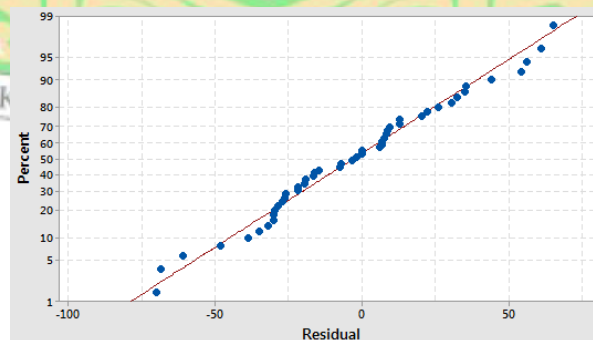


Gambar 3. Plot ACF residu perkembangan wisatawan mancanegara



Gambar 4. Plot PACF of residual perkembangan wisatawan mancanegara

Berdasarkan Gambar 3 dan Gambar 4 terlihat bahwa semua bar tidak ada yang melewati batas signifikansi maka dapat disimpulkan bahwa residual tidak saling berkorelasi atau bersifat white noise.



Gambar 5 Grafik Normal Probability of Residu

Gambar 5 menunjukkan bahwa residu mengikuti garis diagonal, yang berarti residual berdistribusi normal. Karena residual bersifat *white noise* dan

berdistribusi normal maka model dapat digunakan. Berdasarkan hasil analisis di atas, diperoleh empat persamaan model multiplikatif *Holt Winter* dengan α , β dan γ sebesar 0,2, 0,1, 0,1 yaitu :

1. Pemulusan eksponensial data asli

$$L_t = 0,2 \frac{Y_t}{S_{t-12}} + 0,8(L_{t-1} + T_{t-1})$$

2. Pemulusan pola *trend*

$$T_t = 0,1(L_t - L_{t-1}) + 0,9T_{t-1}$$

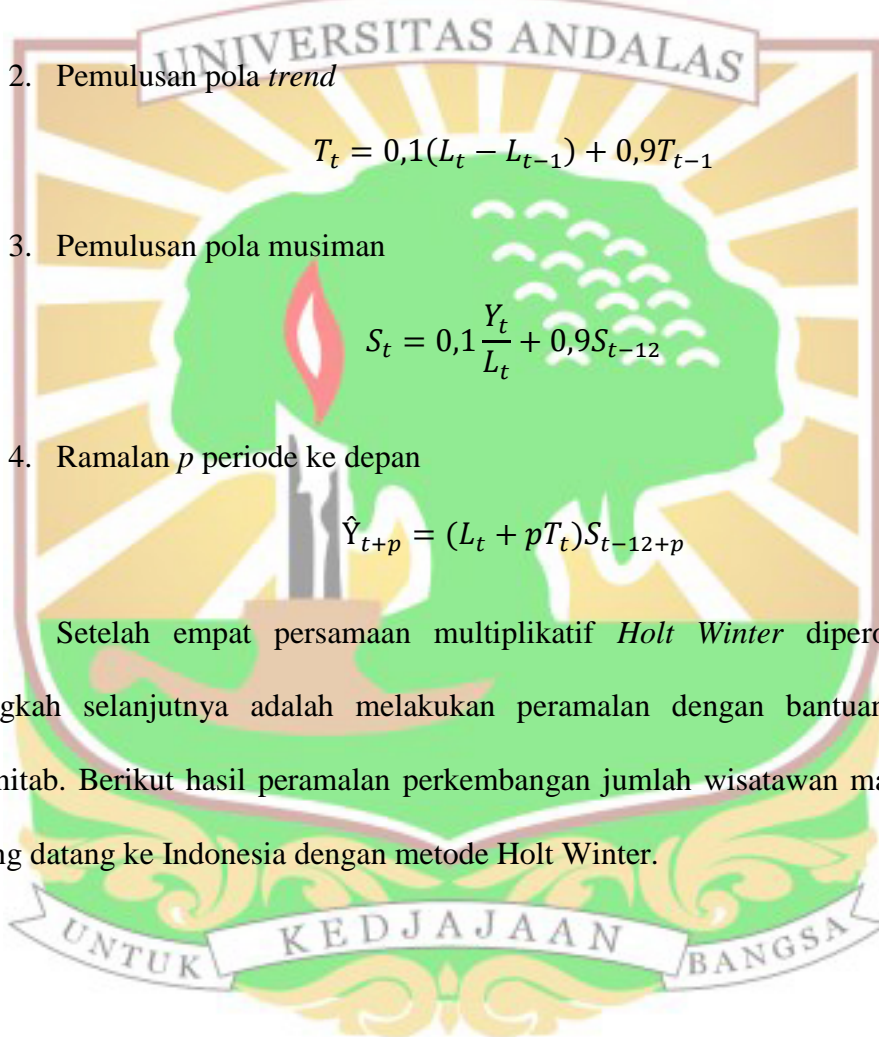
3. Pemulusan pola musiman

$$S_t = 0,1 \frac{Y_t}{L_t} + 0,9S_{t-12}$$

4. Ramalan p periode ke depan

$$\hat{Y}_{t+p} = (L_t + pT_t)S_{t-12+p}$$


Setelah empat persamaan multiplikatif *Holt Winter* diperoleh maka langkah selanjutnya adalah melakukan peramalan dengan bantuan software *minitab*. Berikut hasil peramalan perkembangan jumlah wisatawan mancanegara yang datang ke Indonesia dengan metode *Holt Winter*.



Tabel 4.1.2 Hasil ramalan dengan metode Holt Winter

Bulan	Ramalan
Januari 2015	739,80
Februari 2015	739,79
Maret 2015	806,08
April 2015	762,81
Mei 2015	797,39
Juni 2015	875,19
Juli 2015	870,46
Agustus 2015	832,90
September 2015	838,06
Oktober 2015	842,40
November 2015	851,73
Desember 2015	954,33

Berikut ditampilkan plot data aktual beserta hasil peramalan perkembangan wisatawan mancanegara dengan menggunakan metode Holt Winter untuk periode Januari 2015 – Desember 2015.




Gambar 6. Plot hasil peramalan perkembangan wisatawan dengan metode winter

4.2 Metode Seasonal ARIMA

4.2.1 Identifikasi Data

Langkah pertama yang dilakukan pada tahap identifikasi data yaitu melihat kestasioneran data terhadap ragam dan nilai tengah. Untuk mengetahui kestasioneran data secara umum dilakukan dengan melihat plot data aktual. Berdasarkan Gambar 1, dapat diketahui bahwa data tidak stasioner karena plot data menunjukkan adanya unsur trend dan pola musiman sekaligus karena plot menunjukkan fluktuasi meningkat dari kiri bawah ke kanan atas dan mengandung pola yang berulang setiap tahunnya sehingga data tidak stasioner terhadap ragam dan rata-rata.


Ketidakstasioneran terhadap ragam dapat dilihat dari transformasi Box – Cox. Berikut Box – Cox plot data aktual.



Gambar 7. Box Cox plot data aktual

Berdasarkan Gambar 7 di atas, diketahui nilai *rounded value* sebesar -0,5. Suatu data dikatakan sudah stasioner terhadap ragam apabila nilai *rounded value* (λ) nya adalah 1. Karena nilai *rounded value* yang diperoleh -0,5 maka data tidak stasioner terhadap ragam, maka perlu dilakukan transformasi $1/\sqrt{X_t}$ terhadap

data. Hasil transformasi Box-Cox terlampir pada Lampiran 2. Berikut Box Cox plot dari hasil transformasi $1/\sqrt{X_t}$.



Gambar 8. Box Cox Plot Hasil Transformasi

Berdasarkan Gambar 8 diperoleh nilai *rounded value* (λ) = 1. Jika nilai $\lambda=1$, maka tidak ada transformasi lagi artinya transformasi dihentikan sehingga mengakibatkan ragam sudah konstan sepanjang waktu pengamatan.

Kemudian ketidakstasioneran terhadap nilai tengah pada data hasil transformasi dapat diketahui dengan melakukan uji *Augmented Dickey-Fuller* (ADF), dengan hipotesis sebagai berikut:

H_0 : data tidak stasioner terhadap nilai tengah


H_1 : data stasioner terhadap nilai tengah

Kriteria keputusan penolakan H_0 , jika nilai ADF lebih kecil daripada nilai kritis tabel *Dickey-Fuller* dengan taraf signifikansi $\alpha = 5\%$.

Dari hasil pengujian ADF pada lampiran 3(a), diperoleh bahwa nilai stastitik ADF sebesar -1,262157 dan nilai kritis tabel dengan $\alpha = 5\%$ sebesar -2,913549. Artinya nilai ADF lebih besar daripada nilai kritis tabelnya, maka terima H_0 sehingga dapat disimpulkan bahwa data tidak stasioner terhadap nilai tengah, maka perlu dilakukan *differencing* terhadap data transformasi. Hasil

differencing pertama terhadap data hasil transformasi terlampir pada Lampiran 2.

Berikut plot data *differencing*,




Gambar 9. Plot differencing data aktual

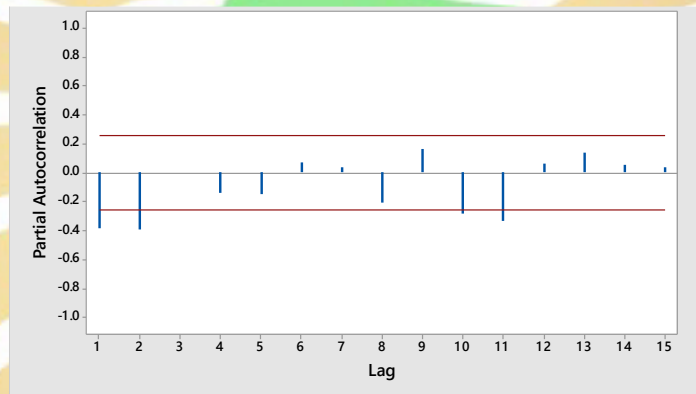
Untuk menguji apakah data sudah stasioner maka dilakukan kembali uji ADF terhadap data *differencing*. Berdasarkan Lampiran 3(b), hasil pengujian ADF data *differencing* diperoleh nilai stastitik ADF sebesar -6,382631 dan nilai kritis tabel dengan $\alpha = 5\%$ sebesar -2,923780. Artinya nilai ADF yang diperoleh lebih kecil daripada nilai kritis tabelnya, maka tolak H_0 , artinya data telah stasioner terhadap nilai tengah.

4.2.2 Identifikasi Model

Setelah data di stasionerkan maka selanjutnya dilakukan identifikasi model, menentukan orde p , d , q . Orde p , d , q dapat diketahui dari korelogram fungsi autokorelasi (ACF) dan fungsi autokorelasi parsial (PACF). Berikut ditampilkan korelogram dari ACF dan PACF data *differencing*.




Gambar 10. Plot ACF dari data differencing




Gambar 11. Plot PACF dari data differencing

Berdasarkan Gambar 10 terlihat bahwa pada korelogram ACF, data *cut off* setelah *lag* 1, sehingga diduga orde model MA yaitu $q = 1$. Sedangkan pada Gambar 11 dari korelogram PACF diketahui bahwa data *cut off* setelah *lag* 2, sehingga diduga orde model AR yaitu $p=2$. Karena ACF dan PACF terhadap data *differencing*, maka diperoleh $d = 1$, dan diduga model awal yang terbentuk adalah model ARIMA(2,1,1). Pada korelogram ACF, terlihat bahwa data masih mengandung musiman, karena signifikan pada *lag* 12. Untuk menghilangkan musiman pada data dilakukan differencing terhadap data musiman dengan panjang musim $S = 12$. Data hasil *differencing* musiman terlampir pada lampiran 2. Berikut ditampilkan plot data hasil *differencing* musiman,




Gambar 12 Plot Data differencing musiman

Setelah data didifferencing musiman, maka selanjutnya kita identifikasi orde P,D,Q. Orde P,D,Q tersebut dapat diketahui melalui korelogram ACF dan PACF. Berikut korelogram ACF dan PACF dari data differencing musiman



Gambar 13 Plot ACF dari differencing musiman



Gambar 14 Plot PACF dari differencing musiman

Dari Gambar 13 terlihat bahwa korelogram ACF data *cut off* setelah *lag 1*, sehingga diduga orde SMA yaitu $Q=1$. Gambar 14 menunjukkan bahwa pada korelogram PACF data *cut off* setelah *lag 2*, sehingga diduga orde SAR yaitu $P=2$. Karena data didifferencing musiman sebanyak satu kali, maka diperoleh orde $D = 1$, sehingga model dugaan awal yang terbentuk adalah ARIMA(2,1,1).

Kemudian dibuat beberapa kemungkinan model SARIMA yang mungkin digunakan untuk peramalan dengan cara menaikkan atau menurunkan orde p,d,q dan P,D,Q dari model awal yang diduga. Berikut beberapa kemungkinan model SARIMA $(p,d,q) (P,D,Q)S$ yaitu:

1. SARIMA (1,1,0)(0,1,1)¹²
2. SARIMA (1,1,0)(1,1,1)¹²
3. SARIMA (2,1,0)(1,1,0)¹²
4. SARIMA (2,1,0)(0,1,1)¹²
5. SARIMA (0,1,1)(1,1,1)¹²
6. SARIMA (2,1,0)(1,1,1)¹²
7. SARIMA (0,1,1)(1,1,0)¹²
8. SARIMA (0,1,1)(0,1,1)¹²
9. SARIMA (1,1,1)(0,1,1)¹²
10. SARIMA (1,1,0)(1,1,0)¹²

4.2.3 Pendugaan Parameter

Pendugaan parameter model dilakukan dengan menggunakan bantuan *software* Minitab. Hasil *output* dari pendugaan parameter terlampir pada Lampiran 5. Berikut tabel pendugaan parameter dari semua kemungkinan model.

Tabel 4.2.3 Pendugaan parameter setiap kemungkinan model SARIMA

Model	Parameter	Taksiran Parameter	Probabilitas	Keterangan
SARIMA (1,1,0)(0,1,1) ¹²	AR (1)	-0,6060	0,000	Signifikan
	SMA (12)	0,4729	0,004	
SARIMA (1,1,0)(1,1,1) ¹²	AR (1)	-0,6060	0,000	Tidak Signifikan
	SAR (12)	0,0000	1,000	
	SMA (12)	0,4730	0,303	
SARIMA (2,1,0)(1,1,0) ¹²	AR(1)	-0,9014	0,000	Signifikan
	AR(2)	-0,4983	0,000	
	SAR(12)	-0,4988	0,003	
SARIMA (2,1,0)(0,1,1) ¹²	AR (1)	-0,8877	0,000	Signifikan
	AR (2)	-0,4555	0,002	
	SMA (12)	0,4232	0,011	
SARIMA (0,1,1)(1,1,1) ¹²	SAR (12)	-0,4571	0,251	Tidak signifikan
	MA (1)	1,0148	0,000	
	SMA (12)	0,0823	0,838	
SARIMA (2,1,0)(1,1,1) ¹²	AR (1)	-0,9000	0,000	Tidak Signifikan
	AR (2)	-0,5086	0,000	
	SAR (12)	-0,6062	0,161	
	SMA (12)	-0,1179	0,796	
SARIMA (0,1,1)(1,1,0) ¹²	SAR (12)	-0,5506	0,001	Signifikan
	MA (1)	1,0060	0,000	
SARIMA (0,1,1)(0,1,1) ¹²	MA (1)	0,9286	0,000	Signifikan
	SMA (12)	0,4743	0,003	
SARIMA (1,1,1)(0,1,1) ¹²	AR (1)	-0,3023	0,115	Tidak Signifikan
	MA (1)	0,6496	0,000	
	SMA (12)	0,4230	0,010	
SARIMA (1,1,0)(1,1,0) ¹²	AR (1)	-0,6008	0,000	Signifikan
	SAR (12)	-0,4327	0,010	

Dari Tabel 4.2.3 diperoleh nilai taksiran parameter dan nilai probabilitas dari setiap kemungkinan model sementara yang dipilih. Tahap selanjutnya

melakukan pengujian parameter dengan menggunakan Uji white noise dan Uji Normalitas.

4.2.4 Diagnostik Model

Dalam menentukan model yang terbaik, harus dipilih model yang seluruh parameternya signifikan, kemudian juga memenuhi 2 asumsi residual yaitu berdistribusi normal dan *white noise*.

a. Distribusi Normal

Pengujian berdistribusi normal dapat dihitung dengan menggunakan Kolmogorov-Smirnov.

Hipotesa :

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Dengan taraf signifikansi $\alpha = 5\%$. Jika nilai p-value $< \alpha$ maka H_0 ditolak, berarti residual tidak berdistribusi normal. Hasil Output dari pengujian residual apakah berdistribusi normal pada Lampiran 4.

b. Uji White Noise

Suatu model bersifat *white noise* artinya residual dari model tersebut independen (antar residual tidak berkorelasi). Pengujian asumsi *white noise* dilakukan dengan menggunakan uji Ljung-Box.

H_0 : $\rho_h = 0$ (tidak terdapat korelasi antar residual)

H_1 : $\rho_h \neq 0$ (terdapat korelasi antar residual)

Dengan taraf signifikansi $\alpha = 5\%$. Jika nilai p-value $> \alpha$ maka H_0 diterima, berarti residual *white noise*. Hasil output dari Uji *white noise* pada Lampiran 5.

Berikut tabel Uji asumsi Residual yaitu Uji Kenormalan dan Uji *White Noise* untuk setiap model yang diduga diawal.

Tabel 4.2.4.1. Tabel Uji Asumsi Residual

Mode	Uji White Noise			Uji Kenormalan residual	
	Lag	P-value	Keterangan	p-value	Keterangan
SARIMA (1,1,0)(0,1,1) ¹²	12	0,048	Tidak White Noise	> 0,15	Normal
	24	0,038			
	36	0,091			
SARIMA (1,1,0)(1,1,1) ¹²	12	0,030	Tidak White Noise	> 0,15	Normal
	24	0,027			
	36	0,073			
SARIMA (2,1,0)(1,1,0) ¹²	12	0,474	White Noise	> 0,15	Normal
	24	0,652			
	36	0,653			
SARIMA (2,1,0)(0,1,1) ¹²	12	0,240	White Noise	> 0,15	Normal
	24	0,248			
	36	0,329			
SARIMA (0,1,1)(1,1,1) ¹²	12	0,077	White Noise	> 0,15	Normal
	24	0,176			
	36	0,126			
SARIMA (2,1,0)(1,1,1) ¹²	12	0,411	White Noise	> 0,15	Normal
	24	0,656			
	36	0,658			
SARIMA (0,1,1)(1,1,0) ¹²	12	0,113	White Noise	> 0,15	Normal
	24	0,214			
	36	0,178			
SARIMA (0,1,1)(0,1,1) ¹²	12	0,104	White Noise	> 0,15	Normal
	24	0,163			
	36	0,078			
SARIMA (1,1,1)(0,1,1) ¹²	12	0,242	White Noise	> 0,15	Normal
	24	0,259			
	36	0,385			
SARIMA (1,1,0)(1,1,0) ¹²	12	0,008	Tidak white Noise	> 0,15	Normal
	24	0,004			
	36	0,020			

Berikut tabel ringkasan Uji Signifikansi, Uji *White Noise* serta Uji Normalitas setiap model dugaan awal.

Tabel 4.2.4.2 Tabel Ringkasan Uji Signifikansi, Uji White Noise, serta Normalitas

Model	Uji Signifikansi Model	Uji White Noise	Uji Normal
SARIMA (1,1,0)(0,1,1) ¹²	Signifikan	Tidak White Noise	Normal
SARIMA (1,1,0)(1,1,1) ¹²	Tidak Signifikan	Tidak White Noise	Normal
SARIMA (2,1,0)(1,1,0) ¹²	Signifikan	White Noise	Normal
SARIMA (2,1,0)(0,1,1) ¹²	Signifikan	White Noise	Normal
SARIMA (0,1,1)(1,1,1) ¹²	Tidak signifikan	White Noise	Normal
SARIMA (2,1,0)(1,1,1) ¹²	Tidak Signifikan	White Noise	Normal
SARIMA (0,1,1)(1,1,0) ¹²	Signifikan	White Noise	Normal
SARIMA (0,1,1)(0,1,1) ¹²	Signifikan	White Noise	Normal
SARIMA (1,1,1)(0,1,1) ¹²	Tidak Signifikan	White Noise	Normal
SARIMA (1,1,0)(1,1,0) ¹²	Signifikan	Tidak white Noise	Normal

Tabel 4.2.4.2 menunjukkan bahwa model SARIMA (2,1,0)(1,1,0)¹², SARIMA(2,1,0)(0,1,1)¹², SARIMA(0,1,1)(1,1,0)¹² serta SARIMA (0,1,1)(0,1,1)¹² yang memenuhi signifikansi, residual berdistribusi normal dan *white noise*.

Selanjutnya dari ke empat model tersebut kita pilih model terbaik yang digunakan dengan cara melihat nilai *MAPE*, *MAD* dan *MSD* yang paling kecil.

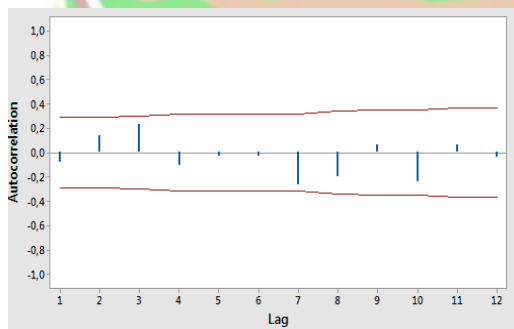
Tabel 4.2.4.3 Tabel Nilai *MAPE*, *MAD* dan *MSD* dari model

Model	Nilai MAPE	Nilai MSD	Nilai MAD
SARIMA (2,1,0) (1,1,0) ¹²	3,49	1108,16	24,45
SARIMA (2,1,0) (0,1,1) ¹²	3,60	1159,05	25,25
SARIMA (0,1,1) (1,1,0) ¹²	3,22	1070,60	22,60
SARIMA (0,1,1) (0,1,1) ¹²	3,50	1187,11	24,54


Dari Tabel 4.2.4.3 di atas, nilai *MAPE*, *MAD* serta *MSD* yang paling kecil yaitu pada model SARIMA(0,1,1)(1,1,0)¹², sehingga model inilah yang paling baik digunakan untuk peramalan dengan persamaan :

$$[(1 - \Phi_1 B^{12})(1 - B)(1 - B^{12})]X_t = (1 - \Theta_1 B)\varepsilon_t$$

Untuk memperkuat kelayakan model terbaik tersebut maka berikut disajikan plot ACF dan PACF residual dari model



Gambar 15. Plot ACF residual



Gambar 16. Plot PACF residual

Grafik ACF dan PACF *residual* pada Gambar 15 dan 16 menunjukkan bahwa tidak ada *lag* yang memotong garis batas atas dan batas bawah nilai

korelasi *residual* sehingga dapat disimpulkan bahwa *residual* yang dihasilkan model tersebut tidak berkorelasi.

Setelah model terbaik didapatkan, langkah selanjutnya adalah kita meramalkan perkembangan wisatawan mancanegara yang datang ke Indonesia.

4.2.5 Peramalan

Setelah model terbaik diperoleh yaitu model SARIMA(0,1,1)(1,1,0)¹², maka langkah selanjutnya adalah melakukan peramalan dengan model terbaik tersebut untuk periode Januari 2015 - Desember 2015. Model terbaik SARIMA(0,1,1)(1,1,0)¹² dapat di tulis sebagai berikut :

$$[(1 - \Phi_1 B^{12})(1 - B)(1 - B^{12})]X_t = (1 - \Theta_1 B)\varepsilon_t$$

(4.2.5.1)

Berikut uraian persamaan (4.2.5.1) :

$$\begin{aligned} [(1 - \Phi_1 B^{12})(1 - B)(1 - B^{12})]X_t &= (1 - \Theta_1 B)\varepsilon_t \\ &= (1 - B^{12} - B + B^{13} - \Phi_1 B^{12} + \Phi_1 B^{24} + \Phi_1 B^{13} - \Phi_1 B^{25}) X_t = (1 - \Theta_1 B)\varepsilon_t \\ &= X_t - B^{12}X_t - BX_t + B^{13}X_t - \Phi_1 B^{12}X_t + \Phi_1 B^{24}X_t + \Phi_1 B^{13}X_t - \Phi_1 B^{25}X_t - \\ &\quad (1 - \Theta_1 B)\varepsilon_t \\ &= X_t - X_{t-12} - X_{t-1} + X_{t-13} - \Phi_1 X_{t-12} + \Phi_1 X_{t-24} + \Phi_1 X_{t-13} - \Phi_1 X_{t-25} - \\ &\quad (1 - \Theta_1 B)\varepsilon_t \\ X_t &= X_{t-12} + X_{t-1} - X_{t-13} + \Phi_1 X_{t-12} - \Phi_1 X_{t-24} - \Phi_1 X_{t-13} + \Phi_1 X_{t-25} + \\ &\quad \varepsilon_t - \Theta_1 \varepsilon_{t-1} \end{aligned}$$

$$X_t = X_{t-1} + (1 + \Phi_1)X_{t-12} - (1 + \Phi_1)X_{t-13} - \Phi_1 X_{t-24} + \Phi_1 X_{t-25} - \Theta_1 \varepsilon_{t-1} + \varepsilon_t \quad (4.2.5.2)$$

Berdasarkan persamaan (4.2.5.2) dapat dibangun model dengan menggunakan taksiran parameter model terbaik sebagai berikut :


$$X_t = X_{t-1} + (1 - 0.5506)X_{t-12} - (1 - 0.5506)X_{t-13} + 0.5506X_{t-24} + -0.5506X_{t-25} - 1.006\varepsilon_{t-1} + \varepsilon_t$$

$$X_t = X_{t-1} + 0.4494(X_{t-12} - X_{t-13}) + 0.5506(X_{t-24} - X_{t-25}) - 1.006\varepsilon_{t-1} + \varepsilon_t \quad (4.2.5.3)$$

Berdasarkan persamaan (4.2.5.3) dapat diperoleh persamaan untuk meramalkan perkembangan wisatawan mancanegara untuk satu periode kedepan yaitu :

$$X_{t+1} = X_t + 0.4494(X_{t-11} - X_{t-12}) + 0.5506(X_{t-23} - X_{t-24}) - 1.006\varepsilon_t + \varepsilon_{t+1}$$

Berikut ditampilkan plot data aktual dan hasil ramalan untuk periode Januari 2015 - Desember 2015 .



Gambar 17. Plot hasil peramalan SARIMA

Berikut ditampilkan data hasil ramalan perkembangan wisatwan mancanegra yang datang ke Indonesia.

Tabel 4.2.5. Tabel hasil Ramalan SARIMA

Periode	Hasil Ramalan.
Januari 2015	782,87
Februari 2015	747,57
Maret 2015	821,34
April 2015	800,80
Mei 2015	816,42
Juni 2015	902,28
Juli 2015	1026,24
Agustus 2015	848,23
September 2015	863,54
Oktober 2015	890,49
November 2015	879,50
Desember 2015	994,52

4.3 Perbandingan hasil Peramalan Metode Holt Winter dengan Seasonal ARIMA


Dari hasil analisis data dengan menggunakan MINITAB, metode Holt Winter dan *Seasonal ARIMA* dapat digunakan untuk meramalkan perkembangan jumlah wisatawan mancanegara yang datang ke Indonesia. Namun, untuk hasil peramalan yang lebih tepat, digunakan metode yang menghasilkan nilai *MAPE*, *MAD* dan *MSD* terkecil untuk memperkecil tingkat kesalahan peramalan. Berikut perbandingan nilai *MAPE*, *MSD* serta *MAD* pada metode *SARIMA* dan *Holt Winter*.

Tabel 4.3.1. Perbandingan nilai *MAPE*, *MAD* serta *MSD* pada Metode Holt Winter dan SARIMA

Metode	Nilai <i>MAPE</i>	Nilai <i>MSD</i>	Nilai <i>MAD</i>
Holt Winter Multiplikatif (0.2; 0.1; 0.1)	3,97	1088,63	26,84
Seasonal ARIMA (0,1,1) (1,1,0) ¹²	3,22	1070,60	22,60

Jadi untuk meramalkan perkembangan jumlah wisatawan mancanegara yang datang ke Indonesia lebih tepat menggunakan model SARIMA (0,1,1) (1,1,0)¹² dari pada metode *Holt Winter* karena metode SARIMA menghasilkan nilai eror *MAPE*, *MAD* serta *MSD* yang lebih kecil.

Berikut plot data hasil ramalan dengan metode Holt Winter, SARIMA dan data aktual .



Gambar 18. Plot data asli dan hasil ramalan Holt Winter dan SARIMA

Berikut tabel eror atau selisih hasil peramalan metode SARIMA dan metode Holt Winter dengan data asli pada periode Januari 2015 sampai dengan Mei 2015.

Tabel 4.3.2. Perbandingan data asli dengan ramalan SARIMA, Holt Winter dan selisihnya

Bulan	Data aktual	Ramalan SARIMA	Ramalan Holt Winter	Selisih	
				SARIMA	Holt Winter
Januari	785,97	782,87	739,80	3,10	46,17
Februari	843,93	747,57	739,79	96,36	104,14
Maret	841,07	821,34	806,08	19,73	34,99
April	801,88	800,80	762,81	1,08	39,07
Mei	852,39	816,42	797,39	35,97	55
Juni	872,38	902,28	875,19	-29,9	-2,81
Juli	877,59	1026,24	870,46	-148,65	7,13
Agustus	911,70	848,23	832,90	63,47	78,8
September	920,13	863,54	838,06	56,59	82,07
Oktober	877,80	890,49	842,40	-12,69	35,4
November	835,41	879,50	851,73	-44,09	-16,32
Desember	986,52	994,52	954,33	-8	32,19

Berdasarkan Tabel 4.3.2 di atas dapat dilihat bahwa eror atau selisih antara data aktual dengan hasil peramalan dengan metode SARIMA lebih kecil dari pada metode Holt Winter. Oleh karena itu untuk meramalkan perkembangan wisatawan mancanegara yang datang ke Indonesia lebih baik menggunakan metode SARIMA daripada metode Holt Winter.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil pengolahan data dapat disimpulkan bahwa:

1. Model Holt Winter dari peramalan perkembangan wisatawan mancanegara yang datang ke Indonesia adalah model multiplikatif Holt Winter dengan persamaan sebagai berikut :

1. Pemulusan eksponensial data asli

$$L_t = 0,2 \frac{Y_t}{S_{t-12}} + 0,8(L_{t-1} + T_{t-1})$$

2. Pemulusan pola *trend*

$$T_t = 0,1(L_t - L_{t-1}) + 0,9T_{t-1}$$

3. Pemulusan pola musiman

$$S_t = 0,1 \frac{Y_t}{L_t} + 0,9S_{t-12}$$

4. Ramalan p periode ke depan

$$\hat{Y}_{t+p} = (L_t + pT_t)S_{t-12+p}$$

2. Model Seasonal ARIMA untuk meramalkan perkembangan wisatawan mancanegara yang datang ke Indonesia yaitu model SARIMA (0,1,1) (1,1,0)¹² dengan bentuk modelnya sebagai berikut :

$$X_{t+1} = X_t + 0.4494(X_{t-11} - X_{t-12}) + 0.5506(X_{t-23} - X_{t-24}) \\ - 1.006\varepsilon_t + \varepsilon_{t+1}$$

3. Model terbaik untuk peramalan perkembangan wisatawan mancanegara yang datang ke Indonesia adalah model SARIMA $(0,1,1)(1,1,0)^{12}$, karena nilai *MAPE*, *MAD* dan *MSD* yang diperoleh lebih kecil daripada model Holt Winter .

5.2 Saran

Berdasarkan hasil analisis data di atas, penulis menggunakan Metode Holt Winter dan Seasonal ARIMA untuk meramalkan perkembangan wisatawan mancanegara yang datang ke Indonesia. Oleh karena itu, pembaca diharapkan dapat mencoba menggunakan metode lain seperti *Double Seasonal ARIMA*.



DAFTAR PUSTAKA

- [1] Badan Pusat Statistik. *Konsep dan Definisi Statistik Kunjungan Wisatawan Mancanegara*. <http://www.bps.go.id> , tanggal akses 11 April 2017
- [2] Brockwell, P.J. dan Davis, R.A. 1996. *Introduction to Time Series and Forecasting*. Spinger Verlag, New York
- [3] Hanke, J.E. & Wichern, D.W. (2005). *Business Forecasting Eight Edition*. New Jersey: Pearson Prentice Hall
- [4] Kementerian Pariwisata. *Statistik Wisatawan Mancanegara*. <http://www.kemenker.go.id> , tanggal akses 10 April 2017
- [5] Makridakis, S., Wheelwright, S.C., & McGee, V.E. (1999). *Metode dan Aplikasi Peramalan Jilid 1* (Ir. Untung Sus Ardiyanto, M.Sc. & Ir. Abdul Basith, M.Sc. Terjemahan). Edisi Kedua. Jakarta: Penerbit Erlangga
- [6] Montgomery, D.C. 2007. *Introduction to Time Series Analysis and Forecasting*. John Wiley And Son, Inc, New York
- [7] Wei, William W.S. 1990. *Time Series Analysis: Univariate and Multivariate Methods*. Addison Wesley, Canada



