

MODEL-MODEL PREDIKSI

Menggunakan Teknik Statistika dan Soft Computing

Purwanto, S.Si, M.Kom, Ph.D
Sunardi, S.S, M.Pd
Dr. Ratih Sari Wardani

**PENERBIT PUSTAKA MAGISSTER
SEMARANG 2018**

ISBN :978-602-0952-84-0

ISBN 978-602-0952-84-0



9 786020 952840

Model-Model Prediksi Menggunakan Teknik Statistika dan Soft Computing

Penulis :

Purwanto;

Sunardi

Ratih Sari Wardani

ISBN: 978-602-0952-84-0

15 x 23cm

ISBN 978-602-0952-84-0



Hak Cipta © Purwanto; Sunardi; Ratih Sari Wardani
Cetakan Pertama, 2018

Diterbitkan pertama kali oleh

Penerbit Pustaka Magister
Jalan Pucangsari timur IV/19 Pucanggading
Demak, Jawa Tengah
elangtuo@yahoo.com
085781054890

KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Allah SWT yang telah melimpahkan rahmat dan hidayah-Nya kepada penulis, sehingga penyusunan Buku Referensi dengan judul Model-Model Prediksi Menggunakan Teknik Statistika dan Soft Computing, dapat terselesaikan.

Materi dari buku ini terdiri dari Data Mining, Model-model prediksi, Evaluasi kinerja Model, Model Prediksi menggunakan SPSS, Penerapan model statistik, model neural network, model Dual Neural Network serta Dual neural network berbasis Particle Swarm Optimization untuk memprediksi wisatawan Jawa Tengah. Perbandingan akurasi model-model prediksi juga dibahas dalam buku ini.

Penulis menyadari bahwa buku ajar ini masih banyak kekurangan dan kelemahan sehingga masih jauh dari sempurna. Oleh karena itu penulis mengharapkan kritik dan saran yang bersifat membangun untuk perbaikan buku ini.

Akhirnya penulis berharap semoga buku ajar ini dapat bermanfaat bagi siapa saja yang mempelajari Model-model prediksi dengan teknik statistika dan soft computing.

Semarang, November 2018

Penulis

DAFTAR ISI

KATA PENGANTAR.....	iii
DAFTAR ISI.....	iv
BAB 1	1
DATA MINING	1
1.1. Pendahuluan.....	1
1. 2. Pengertian Data Mining	2
1.3. Langkah-langkah KDD	3
1.4. Metode Pelatihan (<i>Learning</i>).....	4
1.5. Pengelompokan Data Mining	5
BAB 2	8
MODEL-MODEL PREDIKSI	8
2.1. Model-model Statistika	8
2.1.1. Linear Regression.....	8
2.1.2. Model Autoregressive moving average (ARMA) dan ARIMA.....	9
2.1.3. Eksponensial Smoothing	11
2.2. Model Soft Computing	12
2.3. Kombinasi Model untuk Prediksi	15
BAB 3	17
EVALUASI KINERJA MODEL.....	17

3.1. Jenis-Jenis Ukuran Kinerja Model Prediksi.....	17
BAB 4	19
STUDI KASUS.....	19
DATA WISATAWAN JAWA TENGAH.....	19
4.1. Pendahuluan.....	19
4.2. Data Wisatawan Jawa Tengah.....	20
4.2.1 Data Set Wisatawan Jawa Tengah.....	21
4.3. Pengolahan Data Awal Wisatawan Jawa Tengah	21
BAB 5	24
MODEL PREDIKSI	24
MENGGUNAKAN SPSS	24
5.1. Mengenal SPSS	24
5.2. Window SPSS	25
5.2. Memulai SPSS.....	31
5.3. Membuka Lembar Kerja Baru	35
5.4. Mendefinisikan Variabel.....	36
5.5. Prediksi Pariwisata Jawa Tengah dengan ARMA dan ARIMA.....	42
BAB 6	48
HASIL MODEL-MODEL PREDIKSI.....	48
MODEL STISTIKA DAN SOFT COMPUTING.....	48
6.1. Hasil Model-model Statistika.....	48

6.1.1. Model Regresi Linier.....	48
6.1.2. Model Exponensial Smoothing	50
6.2. ARIMA model untuk prediksi kedatangan turis	74
6.3. Model Linear trend untuk prediksi kedatangan turis	76
6.4. Metode Holt-Winter triple exponential smoothing untuk prediksi kedatangan turis	77
6.5. Hybrid model combining ARIMA and Linear trend untuk prediksi kedatangan turis	78
6.6. Perbandingan Model.....	81
Daftar Pustaka.....	82

BAB 1

DATA MINING

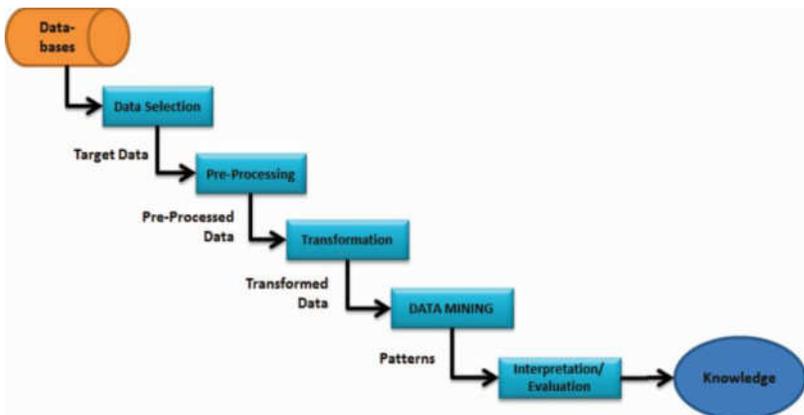
1.1. Pendahuluan

Perkembangan software dan hardware komputer pada dewasa saat ini sangat luar biasa dan pesat. Mereka saling berlomba untuk mengisi dan membantu dalam menyelesaikan pekerjaan. Software menuntut hardware yang lebih canggih, dan sebaliknya hardware menantang agar diisi oleh software dengan teknologi yang lebih canggih. Terkait dengan software, saat ini telah muncul aneka software aplikasi yang dapat digunakan untuk membantu dalam menganalisis suatu permasalahan. Analisis suatu informasi memiliki peran yang sangat penting pada setiap bidang. Setiap harinya, data yang terkumpul pada organisasi pemerintah dan swasta menumpuk sangat banyak. Data-data ini tidak memiliki manfaat yang lebih selama didiamkan saja memenuhi harddisk. Untuk itu perlu me-miningkan data-data tersebut agar memiliki manfaat yang lebih besar. Dengan kata lain, sangat penting untuk

mengelola data dan melaksanakan analisis informasi untuk membantu manajemen dalam pengambilan keputusan.

1. 2. Pengertian Data Mining

Data mining dapat juga merupakan langkah spesifik dalam proses knowledge discovery in databases (KDD) yang digunakan untuk mengekstrak informasi dari database. Definisi dari knowledge discovery pada database dapat dilihat dalam (Vibha & Yashovardhan, 2012). Proses step by step dari KDD yang terdiri dari seleksi data, pengolahan data awal, tranformasi data, data mining dan evaluasi dapat dilihat pada Gambar 1.



Gambar 1: Proses knowledge discovery in databases (KDD)

Sedangkan data mining itu sendiri dapat diasosiasikan dengan knowledge discovery in databases. Data mining merupakan salah satu langkah dalam proses KDD. Model-model yang dipergunakan dalam data mining meliputi klustering, prediksi dan lain-lain.

1.3. Langkah-langkah KDD

Proses knowledge discovery in databases (KDD) dilakukan dengan beberapa langkah, yaitu:

- ❑ *Data Selection*: Langkah ini memilih data yang sesuai dari bermacam-macam database.
- ❑ *Data Pre-processing*: Proses pengolahan data awal dilakukan untuk membersihkan data, seperti mengatasi missing value, menghapus data noise dan lain sebagainya.
- ❑ *Data Transformation*: Data yang dipilih dilakukan proses transformasi dalam bentuk yang sesuai dengan menggunakan metode-metode transformasi.
- ❑ *Data Mining*: Pada langkah ini merupakan langkah terpenting dalam memutuskan model, metode, teknik atau algoritma yang sesuai dalam menyelesaikan suatu masalah.
- ❑ *Interpretation/ Evaluation*: Menginterpretasikan model

atau metode yang dihasilkan dan melakukan evaluasi terhadap model yang dihasilkan tersebut.

1.4. Metode Pelatihan (*Learning*)

Metode pelatihan teknik data mining dibedakan ke dalam dua pendekatan (Santosa, 2007), yaitu :

1. Unsupervised learning, metode ini diterapkan tanpa adanya latihan (training) dan tanpa ada guru (teacher), guru di sini adalah label (output) dari data.
2. Supervised learning, yaitu metode pembelajaran dengan adanya latihan dan pelatih artinya untuk menemukan fungsi keputusan, fungsi pemisah atau fungsi regresi, digunakan beberapa contoh data yang mempunyai output atau label selama proses training. Data yang digunakan untuk membangun model disebut data training dan data yang digunakan untuk menguji model yang dihasilkan digunakan data testing atau data validasi.

1.5. Pengelompokan Data Mining

Pengelompokan data mining berdasarkan tugas yang bisa dilakukan yaitu:

1) Deskripsi

Mencari cara untuk menggambarkan pola dan trend yang terdapat dalam data, contoh mendeskripsikan pola dan trend penyakit. Hasil dari data mining dapat menginterpretasi sesuatu lebih jelas.

2) Estimasi

Estimasi mirip seperti klasifikasi tapi variabel sasaran adalah numerik, model dibangun berdasarkan nilai variabel prediktor.

3) Prediksi

Prediksi digunakan untuk memprediksi masa depan, contoh prediksi jumlah wisatawan mancanegara bulan/ tahun yang akan datang.

4) Klasifikasi

Dalam klasifikasi, sasarannya adalah variabel kategori, klasifikasi ini cocok untuk metode dan teknik data mining. Algoritma akan mengolah

dengan cara membaca data set yang berisi variable predictor dan variable target yang telah diklasifikasikan. Algoritma “mempelajari” kombinasi variabel mana yang berhubungan dengan variabel target, data ini disebut training set. Kemudian algoritma akan melihat ke data baru yang belum termasuk klasifikasi manapun. Berdasarkan klasifikasi pada data set kemudian algoritma akan memasukkan data baru tersebut kedalam klasifikasi yang mana (Whitten, 2011).

5) Clustering

Clustering mengacu pada pengelompokan record-record, observasi, atau kasus-kasus kedalam kelas-kelas dari objek yang mirip. Pada clustering tidak ada variable sasaran. Clustering tidak mengklasifikasi atau mengestimasi atau memprediksi tetapi mencari untuk mensegmentasi seluruh data set ke subgroup yang relative sejenis atau cluster, dimana kemiripan record di dalam cluster dimaksimalkan

dan kemiripan dengan record diluar cluster diminimalkan (Whitten et al, 2011).

6) Asosiasi

Tugas asosiasi untuk data mining adalah kegiatan untuk mencari atribut yang “go together”. Dalam dunia bisnis, asosiasi dikenal sebagai affinity analysis atau market basket analysis, tugas asosiasi adalah membuka rules untuk pengukuran hubungan antara dua atribut atau lebih.

MODEL-MODEL PREDIKSI

2.1. Model-model Statistika

Model-model statistika yang dapat dipergunakan dalam memprediksi untuk univariate data meliputi model-model statistika dan model-model menggunakan soft computing. Model-model statistika mencakup model regresi linier, moving average, eksponensial smoting, ARMA dan ARIMA. Berikut ini adalah model-model statistika unguuk prediksi univariate time series.

2.1.1. Linear Regression

Persamaan model regresi linear sederhana dengan satu variabel bebas x dan variabel terikat y dapat diformulasikan sebagai berikut:

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (2.1)$$

dimana Y_i adalah nilai respon atau variabel bebas, β_0 dan β_1 adalah parameter dan x_i adalah nilai variabel bebas serta $i=1,2,3,\dots$

Nilai prediksi atau estimasi dari model regresi dapat dihitung sebagai (Jamie DeCoster, 2007):

$$\hat{Y}_i = b_0 + b_1 x_i \quad (2.2)$$

Dimana parameter b_0 dan b_1 pada persamaan (1) dapat dihitung sebagai:

$$b_0 = \mu - \beta_1 (n+1)/2$$

$$b_1 = [\theta - n \mu (n+1)/2] / [\sigma^2 - n (n+1)^2 / 4]$$

dimana:

$$\mu = \sum_{i=1}^n x_i / n$$

$$\theta = \sum_{i=1}^n i \cdot x_i \quad (2.3)$$

$$\sigma^2 = \sum_{i=1}^n x_i^2$$

2.1.2. Model Autoregressive moving average (ARMA) dan ARIMA

Data univariate *time series* $\{X_t\}$ adalah serangkaian pengamatan dari variabel selama interval waktu diskrit. Pengamatan memiliki interval waktu yang sama. Dua bagian

dasar dari model linier *time series* adalah model Autoregressive (AR) dan model Moving Average (MA). Prediksi pada model AR adalah fungsi dari pengamatan masa lalu, sedangkan prediksi model MA adalah fungsi dari kesalahan masa lalu.

Model Autoregressive dengan order p , disingkat AR (p) diberikan pada rumus berikut:

$$\hat{x}_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} \quad (2.4)$$

Sedangkan model Moving Average dengan order q , disingkat MA(q) dengan rumus:

$$\hat{x}_t = \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (2.5)$$

Proses Autoregressive moving average (ARMA) adalah merupakan kombinasi dari AR dan MA menjadi satu persamaan. Model ARMA (p, q) didefinisikan (Maia, 2008):

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (2.6)$$

Dimana p adalah order dari model AR dan q adalah order dari model MA.

Model ARMA yang menggunakan order perbedaan d dinamakan model autoregressive integrated moving average (ARIMA). Model ARIMA diformulasikan sebagai

(Brockwell & Davies, 2002):

$$\phi(B)(1-B)^d x_t = \theta(B)e_t \quad (2.7)$$

dimana :

$$B^j x_t = x_{t-j}$$

2.1.3. Eksponensial Smoothing

Model exponential smoothing mengasumsikan bahwa data yang lebih dekat ke data saat ini dipertimbangkan lebih penting untuk memprediksi data ke depan. Ada beberapa model dari exponential smoothing, antara lain single exponential smoothing dan double exponential smoothing. Model dari single exponential smoothing dirumuskan dengan: (Santoso, 2009)

$$\hat{y}_t = \alpha y_t + (1-\alpha)\hat{y}_{t-1} \quad (2.8)$$

dimana α adalah konstan.

Sedangkan untuk double exponential smoothing dinyatakan dengan (Santoso, 2009)

$$\begin{aligned} L_t &= a y_t + (1-a)(L_{t-1} + T_{t-1}) \\ T_t &= \beta (L_t - L_{t-1}) + (1-\beta)T_{t-1} \\ \hat{y}_{t+p} &= L_t + pT_t \end{aligned} \quad (2.9)$$

dimana α dan β adalah konstan, $L_0 = y_1$ dan $T_0=0$.

y_t : Data actual pada waktu $t, t=1, \dots, n$

L, T : Estimasi Level dan Trend pada waktu t

\hat{y}_{t+p} : Nilai prediksi *time series* pada $t+p$

2.2. Model Soft Computing

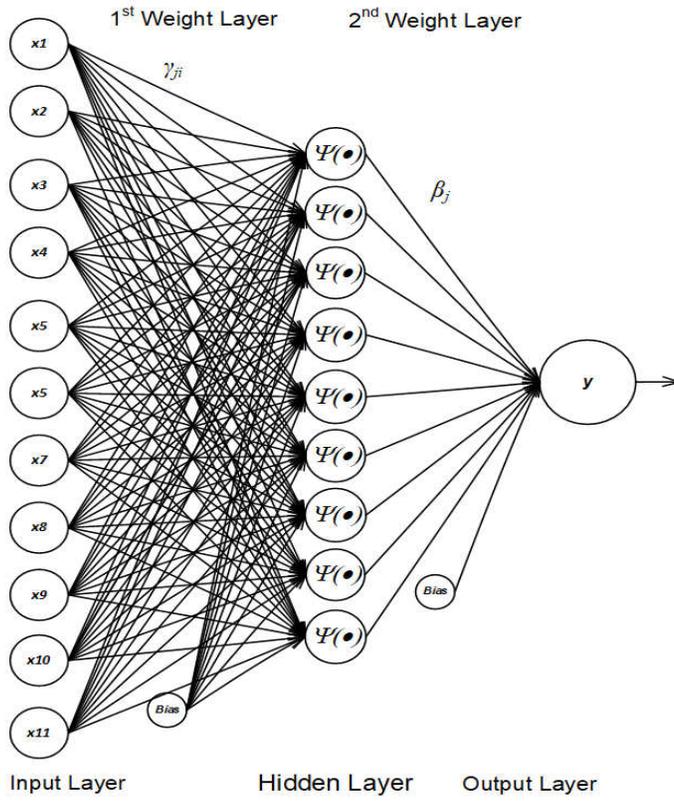
Menurut Lotfi A. Zadeh (1994), *soft computing* adalah kumpulan teknik/ metode yang bertujuan untuk mengeksploitasi adanya toleransi terhadap ketidaktepatan, ketidakpastian dan memberikan biaya rendah dan solusi lengkap. Metode-metode yang termasuk dalam *soft computing* dapat dikelompokkan dalam tiga kelompok besar, yaitu Fuzzy Logic, Probabilistic Reasoning dan Neural Network. Pada penelitian ini akan digunakan metode neural network. Penggunaan metode ini dikarenakan metode ini memiliki kemampuan untuk menangani data non-linier. Arsitektur neural network digunakan secara luas adalah multilayer perceptron (MLP). Pemodelan regresi dan proses sinyal biasanya menggunakan arsitektur MLP. Model MLP terdiri dari layer-layer berbeda yang dihubungkan satu

dengan yang lain dengan bobot koneksi. Layer tersembunyi terletak diantara layer masukan dan layer keluaran. Model neural network dapat diformulasikan sebagai (Suhartono, 2008).

$$y(x) = \beta_0 + \sum_{j=1}^H \beta_j \Psi(\gamma_{j0} + \sum_{i=1}^n \gamma_{ji} x_i), \quad (2.10)$$

dimana $\beta_0, \beta_1, \dots, \beta_H$, dan $\gamma_{10}, \dots, \gamma_{Hn}$ adalah bobot dari Neural network, dan Nilai $y(x)$ adalah output.

Contoh gambar MLP disajikan pada Gambar 2.1



Gambar 2.1 MLP Neural Network 11-9-1

Penggunaan model neural network untuk prediksi telah dilaporkan oleh Song et al. (2005) dan Freeman et al. (2000). Xu et al. (2005) telah melaporkan bahwa JST dan regresi akurasi berdekatan. Model Neural network bekerja lebih efektif dibandingkan dengan model Support

Vector Machine (Hietaniemi et al., 2008).

Song et al. (2005) telah menyarankan bahwa menggabungkan dua buah model mempunyai kemungkinan meningkatkan kinerja dari akurasi prediksi. Sehingga model hybrid yang menggabungkan yang dua buah model yaitu model soft computing dan statistika dapat memberikan akurasi yang baik.

2.3. Kombinasi Model untuk Prediksi

Menurut Zhang (2003), secara umum data time series terdiri dari dua komponen yaitu komponen linear dan komponen non-linier, yang mana dapat diperlihatkan dalam persamaan (2.11).

$$y_t = L_t + N_t,$$

(2.11)

Dimana: L_t sebagai bagian komponen linier, N_t sebagai sebagai komponen non-linier dan y_t sebagai data time series sebagai input. Sedangkan error dari prediksi adalah (Zhang, 2003):

$$e_t = y_t - \hat{L}_t, \quad (2.12)$$

dimana e_t sebagai nilai kesalahan (*error*), \hat{L}_t sebagai nilai
Model-model Prediksi 15

prediksi yang dihitung menggunakan model linier, missal ARIMA. Nilai e_t kemudian diaplikasikan ke neural network (NN) untuk memprediksi bagian non-linier \hat{N}_t . Menurut Zhang (2003), hybrid model dihitung dengan menggunakan rumus pada persamaan (2.13) sebagai:

$$\hat{y}_t = \hat{L}_t + \hat{N}_t, \quad (2.13)$$

Dimana \hat{N}_t adalah nilai prediksi dari bagian N_t yang dihitung dengan model neural network.

BAB 3

EVALUASI KINERJA MODEL

3.1. Jenis-Jenis Ukuran Kinerja Model Prediksi

Untuk mengukur kinerja dari model-model estimasi tersebut, kinerja hasil eksperimen dilakukan dengan menggunakan *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE) dan *Mean Square Error* (MSE) yang dihitung dengan rumus sebagai berikut: (Rojas, 2008).

- a. Mean Absolute Error (MAE).

$$MAE = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n}$$

- b. Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{\sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{Y_i} * 100}{n}$$

c. Root Mean Square Error (RMSE)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$$

d. Mean Square Error (MSE)

$$MSE = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}$$

Dimana Y_t = nilai aktual dan \hat{Y}_t = nilai prediksi, dan n = jumlah data

Kinerja suatu prediksi dapat juga diukur dengan menghitung korelasinya (Correlation= r). Rumus korelasi dinyatakan sebagai berikut:

$$r = \frac{n \sum_{i=1}^n X_i Y_i - \sum_{i=1}^n X_i \sum_{i=1}^n Y_i}{\sqrt{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} \sqrt{n \sum_{i=1}^n Y_i^2 - (\sum_{i=1}^n Y_i)^2}}$$

Dimana X_i = nilai aktual dan Y_i = nilai prediksi, dan n = jumlah data

BAB 4

STUDI KASUS DATA WISATAWAN JAWA TENGAH

4.1. Pendahuluan

Industri pariwisata berperan penting dalam meningkatkan pendapatan devisa negara, sehingga setiap negara berusaha semaksimal mungkin untuk mendatangkan turis internasional (wisatawan mancanegara). Menurut United Nations World Tourism Organization (UNWTO) (2014) yang merupakan organisasi pariwisata dunia, kunjungan wisatawan mancanegara di seluruh dunia diperkirakan akan meningkat sebesar 3,3% per tahun dari tahun 2010 hingga 2030. Diperkirakan pula pada tahun 2030 akan mencapai 1,8 milyar wisatawan mancanegara. Pada tahun 2013, kunjungan wisatawan mancanegara tumbuh 5,0 % dan mencapai 1.087 juta. Asia and the Pacific tercatat memiliki pertumbuhan yang tertinggi yaitu meningkat

sebesar 6,0 %. UNWTO juga melaporkan bahwa penerimaan pariwisata internasional pada tahun 2013 mencapai US \$ 1.159 milyar US \$ 1.078 milyar pada 2012.

Di Indonesia, pada tahun 2013 jumlah kunjungan wisatawan mancanegara mencapai 8,80 juta, meningkat sebesar 9,42% jika dibandingkan dengan jumlah kunjungan pada tahun 2012. Pengeluaran wisatawan mancanegara per kunjungan pada tahun 2013 rata-rata sebesar US\$ 1.142,24 juga mengalami peningkatan sebesar 0,74% jika dibandingkan dengan rata-rata pengeluaran wisatawan mancanegara per kunjungan pada tahun 2012, yaitu sebesar US\$ 1.133,81. (KEMENPAREKRAF, 2014).

4.2. Data Wisatawan Jawa Tengah

Data wisatawan di Jawa Tengah diperoleh dari Dinas Kepemudaan, Olahraga dan Pariwisata Jawa Tengah berupa data time series wisatawan mancanegara di Jawa Tengah dari periode bulan januari 1991 sampai dengan Desember 2013. Dengan kata lain data diperoleh selama 276 bulan. Disamping itu penulis juga mengumpulkan data-data wisatawan di kabupaten/ kota Magelang, Surakarta,

20

Wonosobo dan Kabupaten Semarang. Berikut ini adalah data-data wisatawan Jawa Tengah dan beberapa Kabupaten di Jawa Tengah.

4.2.1 Data Set Wisatawan Jawa Tengah

Data wisatawan di Jawa Tengah ditampilkan dalam tabel 3.1 berikut ini.

Tabel 3.1 Data wisatawan Jawa Tengah

No	Bulan	Tahun									
		1991	1992	1993	1994	1995	1996	1997	1998	...	2013
1	Januari	5,632	26,574	40,698	37,830	48,162	40,496	38,912	32,773		24,740
2	Pebruari	4,444	17,983	39,485	37,025	65,096	48,180	48,300	32,323		21,951
3	Maret	4,983	29,104	42,326	38,574	50,925	49,856	53,492	27,953		25,102
4	April	20,912	35,047	25,138	37,454	48,045	53,966	51,398	27,166		25,429
5	Mei	24,202	42,105	26,465	38,516	48,421	52,828	50,963	16,351		30,360
6	Juni	17,642	29,181	26,394	30,626	45,666	52,780	51,266	6,665		30,302
7	Juli	30,142	43,667	50,289	56,626	80,597	79,616	84,998	18,761		40,429
8	Agustus	50,141	51,398	48,288	63,320	95,408	88,873	88,198	29,939		52,826
9	Sepetember	38,032	44,152	30,784	47,062	63,318	64,106	66,106	23,565		39,396
10	Oktober	40,574	43,513	28,010	39,040	60,772	62,321	45,272	22,931		35,229
11	Nopember	31,388	40,625	28,466	33,990	48,156	50,852	32,924	18,339		29,296
12	Desember	28,345	37,546	21,039	34,137	42,361	47,964	32,219	17,467		33,083

4.3. Pengolahan Data Awal Wisatawan Jawa Tengah

Langkah pertama yang dilakukan dalam pengolahan data awal ini adalah mengecek missing value, dan selanjutnya merubah data univariate time series menjadi

data multivariate. Data univariate diubah sesuai dengan pola data seperti ditunjukkan pada pola Tabel 4.1 berikut ini (Purwanto, 2011):

Tabel 4.1. Membentuk pola data multivariate

Pattern	Input	Output
1	$x_1, x_2, x_3, x_4, \dots, x_p$	x_{p+1}
2	$x_2, x_3, x_4, x_5, \dots, x_{p+1}$	x_{p+2}
3	$x_3, x_4, x_5, x_6, \dots, x_{p+2}$	x_{p+3}
...
$m-p$	$x_{m-p}, x_{m-p+1}, x_{m-p+2}, \dots, x_{m-1}$	x_m

Selanjutnya pola data yang sudah terbentuk dilakukan normalisasi data dengan menggunakan rumus:

$$x' = \frac{(x - \min)(\text{newmax} - \text{newmin})}{(\max - \min)} + \text{newmin} \quad (4.1)$$

Dimana x' = data baru, x = data lama, \min = data minimum, \max =data maksimum, newmax = data maksimum baru dan newmin = data minimum baru.

Dengan menggunakan pengolahan data awal menggunakan tabel 4.1 dan persamaan (4.1) serta dengan inputan 2 periode, maka akan dihasilkan tabel 4.2 sebagai berikut:

Tabel 4.2. Hasil pengolahan data awal

No	Variabel		
	xt-2	xt-1	xt
1	0.331907	0.267940	0.308770
2	0.376833	0.331907	0.267940
3	0.521628	0.376833	0.331907
4	0.387970	0.521628	0.376833
5	0.278786	0.387970	0.521628
6	0.279412	0.278786	0.387970
7	0.226248	0.279412	0.278786
8	0.222723	0.226248	0.279412
9	0.188751	0.222723	0.226248
10	0.218820	0.188751	0.222723
11	0.262097	0.218820	0.188751
12	0.228071	0.262097	0.218820
13	0.387841	0.228071	0.262097
14	0.402320	0.387841	0.228071
15	0.401296	0.402320	0.387841
...
274	0.012808	0	0.005811

MODEL PREDIKSI MENGUNAKAN SPSS

5.1. Mengenal SPSS

SPSS (*Statistical Product And Service Solutions*) merupakan perangkat lunak untuk pengelolaan data. Dengan memanfaatkan perangkat lunak tersebut kita dapat menentukan struktur data, memasukkan data, menyimpan data, menyajikan dan menganalisis data sehingga diperoleh informasi yang dapat digunakan untuk pengambilan keputusan. Data yang akan dikelola dapat berupa angka maupun narasi. Informasi yang dihasilkan merupakan hasil pemrosesan data dengan pendekatan statistik, sehingga dengan SPSS akan dapat dilakukan analisis guna mendeskripsikan data maupun untuk mengetahui adanya keterkaitan antara variabel. Pendeskripsian data dilakukan

dengan menampilkan mean, standar deviasi, nilai minimal, nilai maksimal dan grafik. Sedangkan keterkaitan antara variabel dilakukan dengan korelasi, regresi maupun tabulasi silang.

SPSS merupakan salah satu program pengolahan data statistik yang paling banyak diminati oleh para peneliti karena sifatnya fleksibel dan dapat digunakan untuk hampir semua bentuk dan tingkatan penelitian. Saat sekarang ini produk SPSS telah digunakan dalam berbagai berbagai bidang seperti Retail, Telekomunikasi, Farmasi, Keuangan, Manajemen, Kesehatan dan lain-lain.

5.2. Window SPSS

SPSS menyediakan window, yaitu :

1. Data Editor

Window ini terbuka secara otomatis setiap kali program SPSS dijalankan, dan berfungsi untuk input data SPSS.

Menu yang ada pada data editor

File

Menu File berfungsi untuk menangani hal-hal yang

berhubungan dengan file data, seperti membuat file baru, membuka file tertentu dan sebagainya.

□ Edit

Menu Edit berfungsi untuk menangani hal-hal yang berhubungan dengan memperbaiki atau mengubah nilai data, seperti duplikasi data, menghapus data dan sebagainya.

□ View

Menu View berfungsi untuk mengatur toolbar

□ Data

Menu data berfungsi untuk membuat perubahan data SPSS secara keseluruhan, seperti mengurutkan data, menyeleksi data berdasar kriteria tertentu dan sebagainya.

□ Transform

Menu Transform berfungsi untuk membuat perubahan pada variabel yang telah dipilih dengan kriteria tertentu.

□ Analyze

Merupakan menu inti yang berfungsi untuk melakukan semua prosedur perhitungan statistiks.

- Direct Marketing
Merupakan menu inti yang berfungsi untuk melakukan analisis marketing.
- Graphs
Menu graphs berfungsi untuk membuat berbagai jenis grafik
- Utilities
Menu Utilities adalah menu tambahan yang mendukung program SPSS, seperti memberi informasi tentang variabel yang sekarang sedang dijalankan, menjalankan scripts dan mengatur tampilan menu-menu yang lain.
- Add_ons
Adalah menu yang berisi software lain misalnya amos dll, service, extension program dan statistical guide
- Window
Menu Window berfungsi untuk berpindah diantara menu-menu yang lain di SPSS.
- Help
Menu Help berfungsi untuk menyediakan informasi mengenai program SPSS yang bisa diakses secara mudah dan jelas

2. Menu Output Navigator

Menu yang berfungsi untuk menampilkan hasil pengolahan data, menu output pada prinsipnya sama dengan menu editor dengan disesuaikan untuk kegunaan output SPSS dengan menu tambahan yaitu :

- Insert
Berfungsi untuk menyisipi judul, grafik, teks atau obyek tertentu dari aplikasi lain.
- Format
Berfungsi untuk mengubah tata letak huruf

3. Menu Pivot Table Editor

Menu pivot table editor berhubungan dengan pengerjaan tabel SPSS seperti mentransformasikan tabel menjadi kolom dan sebaliknya, memindah baris dan kolom tabel dan sebagainya. Menu pivot table editor mempunyai submenu hampir sama dengan menu output editor dengan tambahan menu PIVOT yang khusus digunakan untuk pengerjaan pivoting (mengubah status pivoting trays dan

pengerjaan multidimensional pivot tabel).

4. Menu Chart Editor

Menu ini merupakan tempat edit bagi output hasil pengerjaan data dimenu editor, khususnya untuk output berupa grafik/chart/diagram. Sesuai dengan fungsinya selain submenu dasar chart editor dilengkapi submenu tambahan, yaitu:

- Gallery

Submenu ini berfungsi untuk mengubah jenis chart, seperti dari bentuk grafik batang ke bentuk garis dan sebagainya.

- Chart

Untuk mengedit berbagai hal mengenai grafik, seperti layout, skala grafik dan sebagainya.

- Series

Untuk memilih kelompok data tertentu, transpose data atau menampilkan seri data.

5. Menu Text Output Editor

Berfungsi untuk edit output yang berupa teks atau tulisan.

6. Menu Syntax Editor

Menu ini berupa file teks yang berisi berbagai perintah atau pilihan yang hanya bisa digunakan dengan SPSS command language dan bisa diketik secara manual. Namun SPSS juga menyediakan berbagai kemudahan untuk pembuatan syntax, seperti lewat Output Log, Journal File dan lainnya. Isi menu syntax sama dengan menu yang lain hanya ada tambahan menu Run yang berfungsi untuk menjalankan Syntax yang sudah ditulis.

7. Menu Script Editor

Menu Scripts digunakan untuk melakukan berbagai pengerjaan SPSS secara otomatis seperti membuka dan menutup file, ekspor chart, penyesuaian bentuk output dan lainnya. Isi menu sama dengan menu terdahulu, hanya ditambah dengan submenu Script untuk membuat berbagai subrutin dan fungsi baru, serta submenu Debug untuk melakukan proses debug pada script.

5.2. Memulai SPSS

Untuk mengaktifkan SPSS dapat dilakukan dengan beberapa cara yaitu :

- a. Dari Menu Start

Klik **Start > Program > SPSS for Windows > SPSS 15/16/17/IBM SPSS 20.0 for Windows**, seperti tampak pada gambar 1.

- b. Jika sebelumnya sudah disediakan shortcut, pilih icon yang berbentuk gambar SPSS.



Gambar 5.1. Memulai SPSS

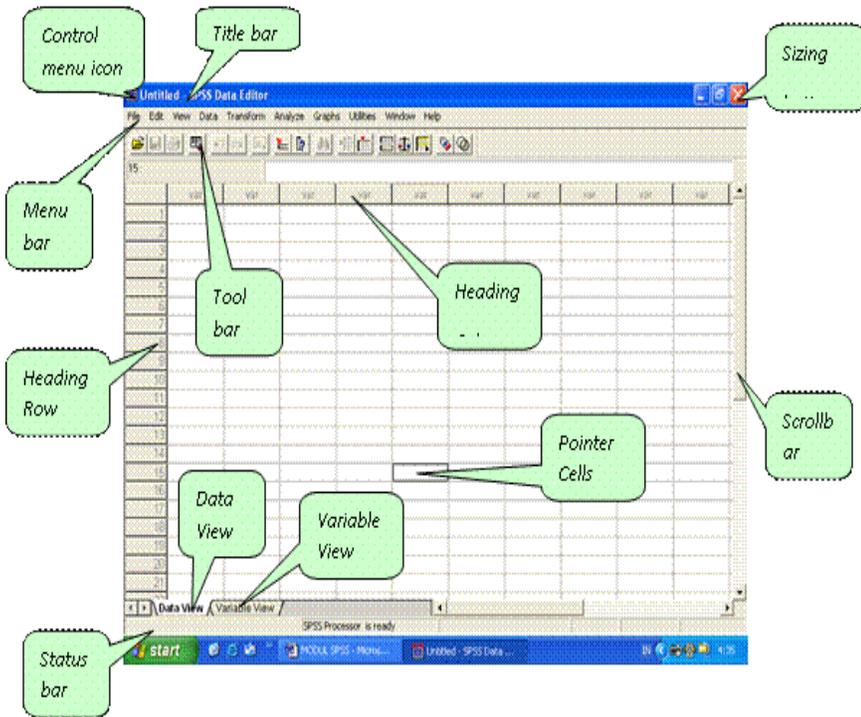
Selanjutnya akan dimunculkan kotak dialog sebagai berikut :



Figure 1.1. Dialog box SPSS for Windows

Pada kotak dialog awal SPSS disediakan beberapa pilihan yang akan dilakukan yaitu :

Run the tutorial, Type in data, run an existing query, creates new query using database wizard, Open an existing file dan Open an existing data source. Jika ingin membuat file baru klik **Cancel** dan selanjutnya akan muncul layar kosong SPSS dibawah ini :



Gambar 5.3. Tampilan Layar SPSS

Elemen dasar SPSS Data editor yang perlu anda ketahui di antaranya :

1. **Icon Kontrol Menu (Control Menu Icon)**, digunakan untuk mengontrol jendela yang sedang aktif.
2. **Baris Judul (Title Bar)**, berisi nama file dan nama program aplikasi yang sedang aktif, baris judul ini dapat juga digunakan untuk memindahkan jendela ke posisi lain

3. **Baris Menu (*Menu Bar*)**, berisi barisan perintah berupa menu seperti menu **File, Edit, View, Data, Transform, Analyze, Direct Marketing, Graphs, Utilities, Windows** dan **Help**.
4. **Baris Toolbar (*Toolbars*)**, berisi tombol-tombol yang digunakan untuk menjalankan suatu perintah dengan cepat dan mudah, terutama perintah-perintah yang sering anda gunakan.
5. **Baris Penggulung (*Scroll Bar*)**, untuk menggeser layar ke kiri dan ke kanan gunakan penggulung mendatar sedangkan untuk ke atas dan ke bawah gunakan baris penggulung tegak.
6. **Pointer sel (*Cell pointer*)**, digunakan untuk menunjuk sel (perpotongan antara baris dan kolom) yang aktif.
7. **Judul baris (*Heading row*)**, berisi nomor urut baris.
8. **Judul kolom (*Heading Column*)**, berisi nama variabel.
9. **Baris status (*Status bar*)**, digunakan untuk melihat perintah yang sedang dijalankan.
10. **Tombol Ukuran (*Sizing Button*)**

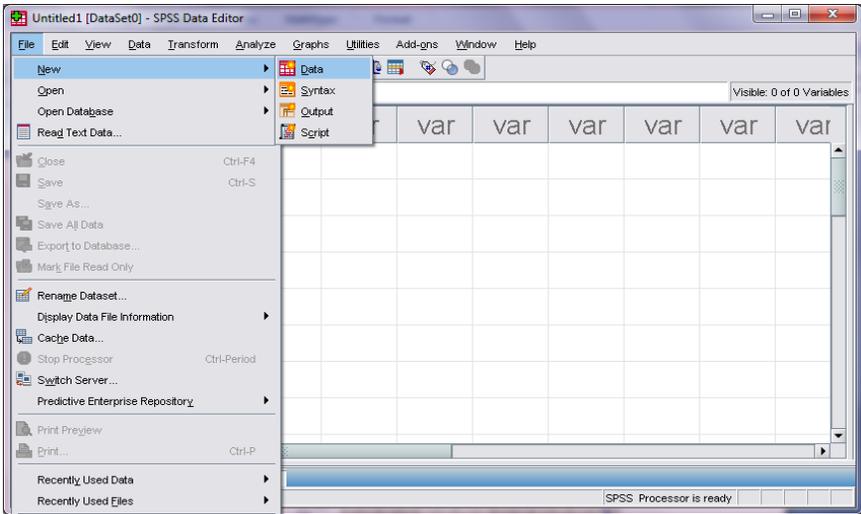
Tombol	Keterangan
	Tombol Minimize untuk memperkecil jendela hingga membentuk icon aktif pada taskbar
	Tombol maximize untuk memperbesar ukuran jendela hingga menjadi satu layar penuh
	Tombol Restore untuk mengembalikan jendela pada ukuran semula
	Tombol Close untuk menutup jendela dan mengakhiri program aplikasi

11. **Tampilan data (*Data View*)**, digunakan untuk menampilkan data.
12. **Tampilan variabel (*Variable View*)**, digunakan untuk menampilkan define variabel.

5.3. Membuka Lembar Kerja Baru

Pilih dan klik menu **File, New, Data** seperti tampilan pada gambar 5.4, selanjutnya baru dapat mulai mengisikan

data baru pada ruang kerja seperti yang diperlihatkan pada gambar 5.3.



Gambar 5.4 . Tampilan Pembuatan file baru

5.4. Mendefinisikan Variabel

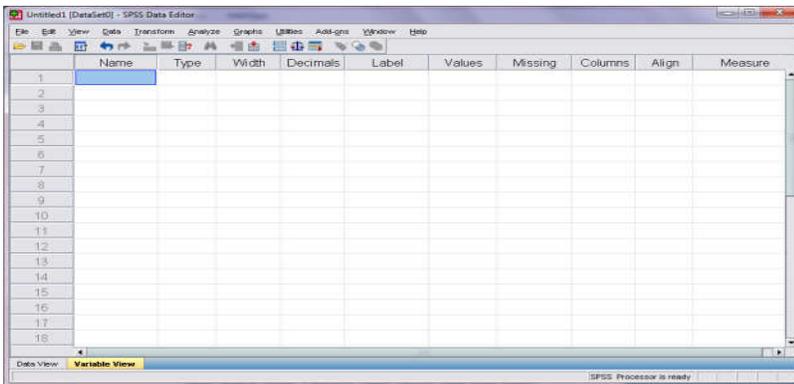
Langkah pertama yang perlu dilakukan untuk pengelolaan data adalah membuat struktur data dalam rangka menghasilkan variabel. Struktur data adalah uraian yang terperinci dari setiap data, yang selanjutnya dapat memberikan beberapa keuntungan diantaranya adalah : dapat dengan mudah memanggil data yang diinginkan,

dapat menggunakan nama variabel untuk memanggil data, dapat melakukan analisis data berdasarkan jenis variabel.

Sebelum mengisi data, perlu dilakukan pendefinisian variabel yang datanya akan dimasukkan. Ada dua cara dalam mendefinisikan variabel, yaitu :

- a. Cara pertama
 - Klik pada **Variable View**
- b. Cara Kedua
 - Letakkan pointer pada heading kolom
 - Lakukan klik ganda pada heading kolom tersebut.

Sehingga akan muncul kotak dialog *Define Variable* sebagai berikut :



Gambar 5.5 . Tampilan *Define Variable*

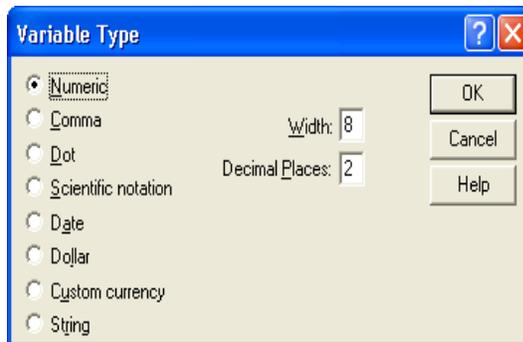
Untuk keperluan penggunaan SPSS, struktur data pada define variable terdiri dari :

Name : menentukan nama variabel yang akan disimpan.

Pada saat *default*, isi nama variabel adalah VAR0001. Nama variabel tidak boleh terlalu panjang, dibatasi 8 karakter tanpa spasi, dimulai dengan huruf bukan angka atau tanda baca/symbol.

Type : berguna menentukan tipe variabel, lebar karakter variabel dan jumlah angka desimal.

Klik **heading type**, klik kotak kecil sebelah kanan sel maka akan akan muncul kotak dialog seperti gambar di bawah ini :



Gambar 5.6. Kotak dialog *Variable Type*

Terdapat 8 jenis variabel, yaitu

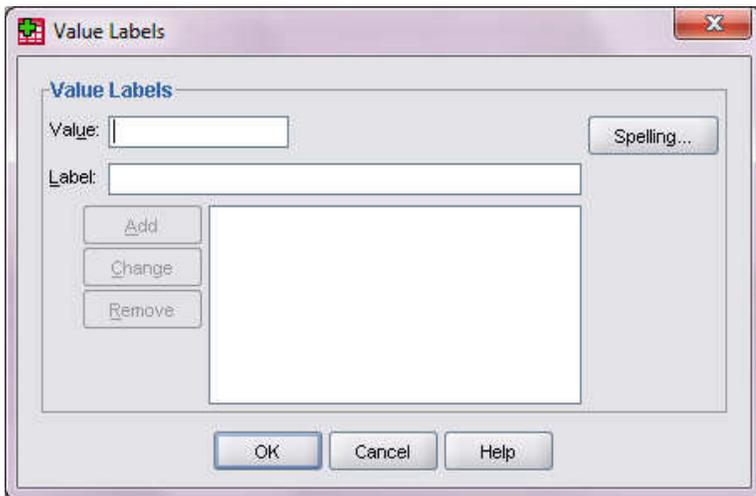
- Numeric** : data berbentuk angka, dapat mempunyai nilai desimal atau dalam bentuk bilangan bulat.
- Comma** : data berbentuk angka dengan pemisah setiap tiga bilangan dan pemisah desimalnya titik.
- Dot** : data berbentuk angka dengan pemisah setiap tiga bilangan dan pemisah desimalnya koma.
- Scientific notation** : variabel numerik yang nilainya ditunjukkan dengan eksponen.
- Date** : data berupa tanggal dengan beberapa format, misalnya dd-mm-yy, mm/dd/yy , dan lain-lain.
- Dollar** : data menunjukkan besarnya dana yang disimpan dalam \$
- Custom currency** : variabel numerik yang ditunjukkan dalam pilihan format sesuai dengan yang tersedia dalam kotak dialog.
- String** : data karakter terdiri dari narasi atau campuran narasi dan angka.

Width : jumlah digit yang harus disediakan agar dapat digunakan untuk menyimpan data.

Label : keterangan lengkap dari suatu variabel

Value : angka yang menunjukkan katagori-katagori dari suatu variabel.

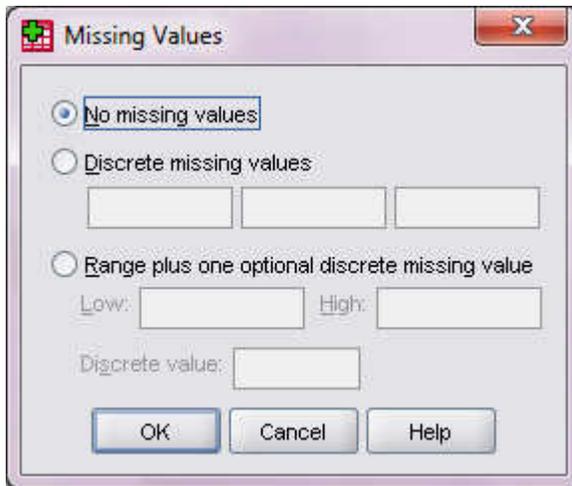
Klik **heading value**, klik kotak kecil sebelah kanan sel maka akan akan muncul kotak dialog seperti gambar di bawah ini :



Gambar 5.7. Kotak dialog *Value Labels*

Missing Values : tombol pilihan pada missing values berguna untuk menjelaskan data variabel yang dianggap sebagai nilai yang salah atau keliru.

Klik **heading missing value**, klik kotak kecil sebelah kanan sel maka akan muncul kotak dialog seperti gambar di bawah ini :



Gambar 5.8. Kotak dialog *Missing Values*

Terdapat 3 pilihan dalam kotak dialog missing values, yaitu :

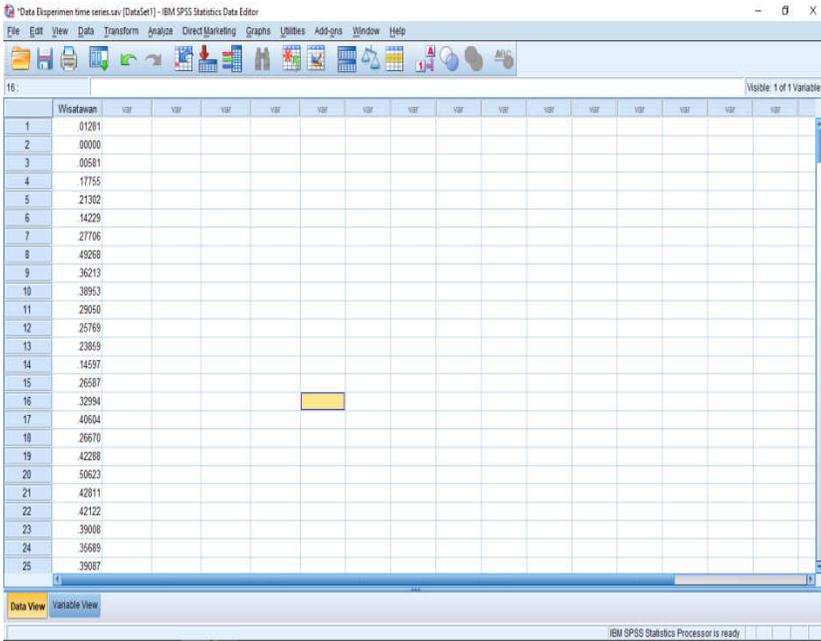
- **No Missing Values**, jika variabel tersebut tidak memiliki missing value

- **Discrete Missing Variabel**, jika pada variabel terdapat 1,2 atau 3 buah missing value dengan hanya mengisikan harga-harga missing value pada kotak yang tersedia.
- **Range Plus One Discrete Missing Values**, jika pada variabel tersebut terdapat missing value berupa interval suatu bilangan dan sebuah harga missing value yang berupa alternatif.
- **Column** : digunakan untuk menentukan lebar kolom dengan hanya mengklik dua kali pada pilihan kolom tersebut lalu tentukan lebar kolom sesuai keinginan.
- **Align** : digunakan untuk meratakan data (rata kiri, rata tengah atau kanan).
- **Measure**: digunakan untuk menentukan skala pengukuran dari suatu variabel, terdiri 3 pilihan scale (rasio/interval), ordinal dan nominal.

5.5. Prediksi Pariwisata Jawa Tengah dengan ARMA dan ARIMA

Dalam prediksi wisatawan mancanegara Jawa Tengah, dapat digunakan SPSS untuk menentukan kinerja pada

model ARIMA dan ARMA. Input data dalam SPSS ditunjukkan dalam Gambar 5.9

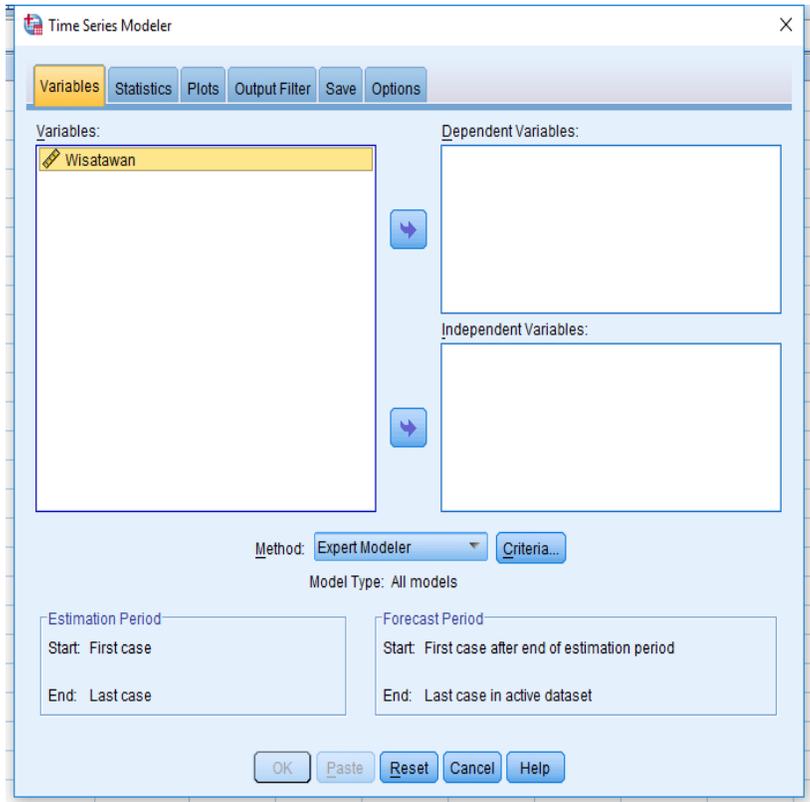


The screenshot shows the IBM SPSS Statistics Data Editor interface. The main window displays a data grid with 25 rows and 16 columns. The first column is labeled 'Wisatawan' and contains numerical values ranging from 01281 to 39087. The remaining 15 columns are empty, with a yellow highlight on the cell in row 16, column 16. The interface includes a menu bar (File, Edit, View, Data, Transform, Analyze, Direct Marketing, Graphs, Utilities, Add-ons, Window, Help) and a toolbar with various icons. The status bar at the bottom indicates 'IBM SPSS Statistics Processor is ready'.

	Wisatawan														
1	01281														
2	00000														
3	00581														
4	17755														
5	21302														
6	14229														
7	27706														
8	49268														
9	36213														
10	38953														
11	29050														
12	25769														
13	23859														
14	14597														
15	26587														
16	32994														
17	40604														
18	26670														
19	42288														
20	50623														
21	42811														
22	42122														
23	39008														
24	35689														
25	39087														

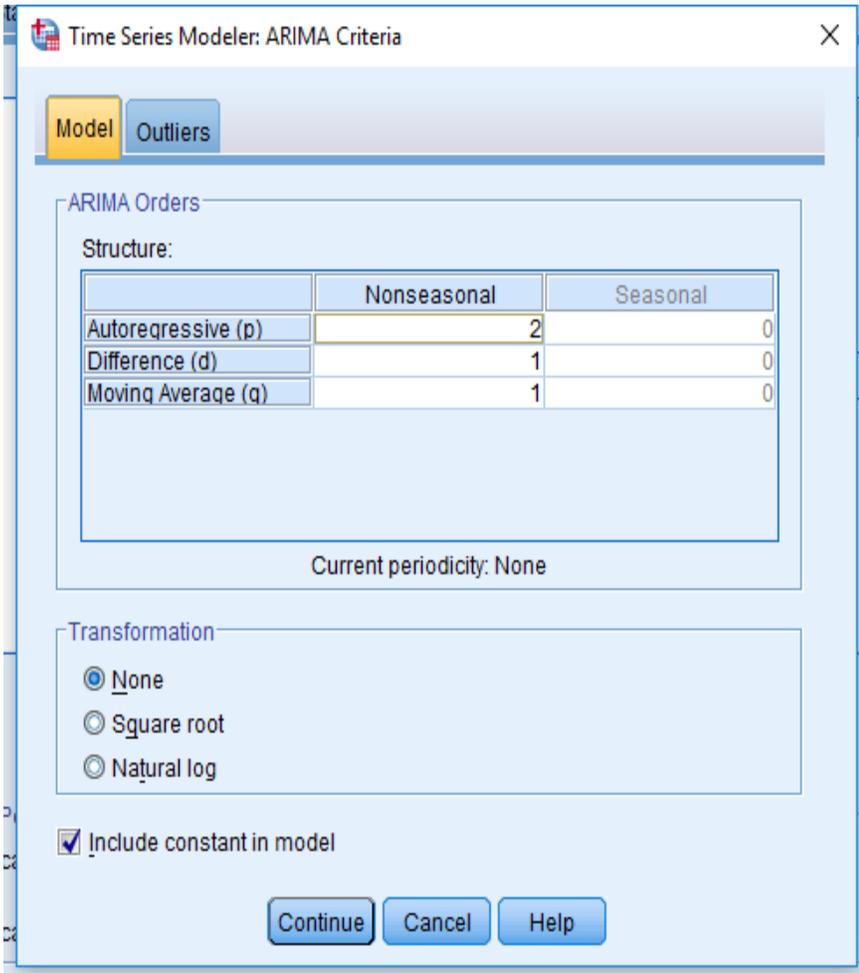
Gambar 5.9 Input data wisatawan Jawa Tengah

Untuk melakukan pemodelan menggunakan ARMA dan ARIMA selanjutnya menggunakan Analyze, Forecasting dan Create Model, seperti yang ditampilkan Gambar 5.10. Selanjutnya menentukan model yang akan dipergunakan dengan memilih Expert Modeler.



Gambar 5.10 Menentukan model ARMA dan ARIMA

Selanjutnya pilih ARIMA dan Criteria (memilih nilai parameter p , d , dan q). Misalnya ARIMA (1, 1, 1) dengan nilai parameter $p=2$, $d=1$ dan $q=1$. Pilihan parameter ARIMA tertampil pada Gambar 5.11.



Gambar 5.11 Menentukan parameter ARIMA

Hasil kinerja model ARIMA(2,1,1) menggunakan SPSS dihasilkan seperti Gambar 5.12.

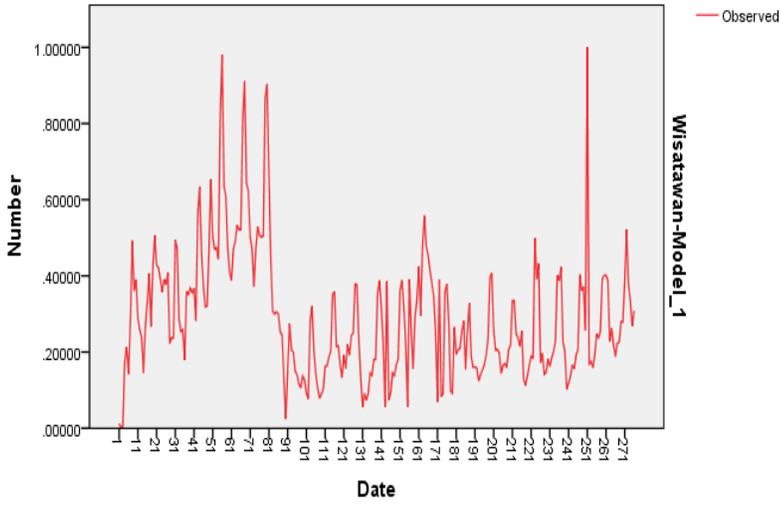
Fit Statistic	Mean	SE	Minimum	Maximum	Percentile						
					5	10	25	50	75	90	95
Stationary R-squared	.156	.	.156	.156	.156	.156	.156	.156	.156	.156	.156
R-squared	.517	.	.517	.517	.517	.517	.517	.517	.517	.517	.517
RMSE	.118	.	.118	.118	.118	.118	.118	.118	.118	.118	.118
MAPE	37.673	.	37.673	37.673	37.673	37.673	37.673	37.673	37.673	37.673	37.673
MaxAPE	922.011	.	922.011	922.011	922.011	922.011	922.011	922.011	922.011	922.011	922.011
MAE	.078	.	.078	.078	.078	.078	.078	.078	.078	.078	.078
MaxAE	.742	.	.742	.742	.742	.742	.742	.742	.742	.742	.742
Normalized BIC	-4.190	.	-4.190	-4.190	-4.190	-4.190	-4.190	-4.190	-4.190	-4.190	-4.190

Model	Number of Predictors	Model Fit statistics	Ljung-Box Q(18)			Number of Outliers
		Stationary R-squared	Statistics	DF	Sig.	
Wisatawan-Model_1	0	.156	69.066	15	.000	0

Gambar 5.12 Hasil kinerja ARIMA (2,1,1)

Dari Gambar 5.12 terlihat bahwa kinerja model ARIMA (2,1,1) yaitu RMSE= 0.118. Untuk model-model ARIMA yang lain dapat dilakukan dengan memasukkan nilai parameter yang berbeda-beda. Untuk model ARMA dapat dilakukan dengan memasukkan nilai $d=0$.

Dan Grafik data time series wisatawan Jawa Tengah ditampilkan pada Gambar 5.13, yang menunjukkan bahwa jumlah wisatawan Jawa Tengah menunjukkan turun naik dan membentuk garis non-linier.



Gambar 5.13 Grafik Wisatawan Jawa Tengah

BAB 6

HASIL MODEL-MODEL PREDIKSI MODEL STATISTIKA DAN SOFT COMPUTING

Model/ metode prediksi dapat dilakukan dengan teknik-teknik statistika yang meliputi *regresi linier*, *moving average*, *single exponential smoothing*, *double exponential smoothing* dan ARIMA. Sedangkan model lain yang digunakan adalah *k-Nearest Neighbor* dan Neural Network. Selanjutnya model/ metode tersebut dievaluasi dan ditentukan model/ metode terbaik.

6.1. Hasil Model-model Statistika

6.1.1. Model Regresi Linier.

Setelah melakukan pemodelan dengan data wisatawan mancanegara Jawa Tengah, model regresi linier (trend) yang didapatkan adalah persamaan regresi linier sebagai berikut:

$$x_t = 0.36697 - 0.00053299 * t$$

Pada model regresi linier (trend) diperoleh kinerja model, yaitu nilai RMSE sebesar 0.1644 dan MSE sebesar 0.02706.

6.1.2 Model Moving Average

Untuk model Moving Average, dilakukan banyak eksperimen dengan menggunakan beberapa nilai m , dan hasil yang diperoleh adalah:

Tabel 6.1. Perbandingan Kinerja Model Moving Average

Model	MSE	RMSE
MA (2)	0.016753	0.129433
MA (3)	0.017987	0.134116
MA (5)	0.019498	0.139635
MA (8)	0.020366	0.142709
MA (10)	0.019897	0.141057
MA (11)	0.019085	0.138148

Dari Tabel 6.1, terlihat bahwa model Moving average dengan jumlah periode 2 adalah paling baik, karena nilai RMSE paling kecil.

6.1.2. Model Exponensial Smoothing

Untuk model exponensial smoothing meliputi model Single Exponential Smoothing, Double Smoothing dan Triple Smoothing. Single Exponential Smoothing dilakukan eksperimen dengan berbagai nilai α , dan untuk model Double Smoothing dan Triple Smoothing. Single Exponential Smoothing juga dilakukan dengan berbagai macam nilai parameter. Hasil kinerja model-model tersebut ditunjukkan pada Tabel 6.2, sebagai berikut:

Tabel 6.2. Kinerja Model Exponensial Smoothing

MODELS		MSE	RMSE
Single ES	0.1	0.01933	0.13903
	0.3	0.01616	0.12713
	0.6	0.01508	0.12279
	0.8	0.01527	0.12357
	0.9	0.01565	0.12512
	1.0	0.01626	0.12752
DOUBLE ES (Holt)		MSE	RMSE
0.1	0.1	0.02130	0.14595
0.1	0.2	0.02230	0.14932
0.2	0.1	0.01913	0.13830
0.2	0.2	0.02068	0.14381
TRIPLE ES (Winter)		MSE	RMSE
(0.1, 0.1, 0.2)		0.08044	0.28361
(0.2, 0.2, 0.2)		0.02027	0.14237
(0.3, 0.3, 0.3)		0.02147	0.14653

Dari tabel 6.2, terlihat bahwa model Single ES dengan $\alpha = 0.6$ merupakan yang terbaik, karena memiliki nilai terkecil dari RMSE.

6.2 Model k-Nearest Neighbor

Pada model prediksi pariwisata mancanegara menggunakan metode k-NN, peneliti melakukan percobaan dengan nilai k dari 1 sampai dengan 20. Tabel 6.3 berikut merupakan hasil performa dari metode k-NN berdasarkan nilai RMSE dan hanya diambil 10 nilai dari k pada k-NN.

Tabel 6.3. Perbandingan Kinerja model menggunakan K-Nearest Neighbor

Metode	MSE	RMSE
1-NN	0.02341	0.153
2-NN	0.01960	0.14
3-NN	0.01638	0.128
4-NN	0.01563	0.125
6-NN	0.01488	0.122
7-NN	0.01513	0.123
9-NN	0.01563	0.125
11-NN	0.01613	0.127
13-NN	0.01588	0.126
17-NN	0.01588	0.126

Dari tabel 6.3, terlihat bahwa model 6-Nearest Neighbor memberikan nilai RMSE terkecil. Ini menunjukkan bahwa model 6-NN merupakan model terbaik dibandingkan dengan nilai k yang lain.

6.3 Model Neural Network

Model Neural network telah sukses dan diaplikasikan untuk prediksi di berbagai bidang. Dalam penelitian ini, model neural network akan digunakan untuk memprediksi jumlah wisatawan mancanegara. Untuk mencari kinerja terbaik dari model Neural network, akan dicari konfigurasi terbaik dari model ini, dengan melakukan eksperimen dengan parameter iterasi=1.000, learning rate=0.1., momentum=0.2, jumlah neuron di hidden layer bervariasi, dan jumlah hidden layer yang berjumlah 1 dan 2 layer. Tabel 6.4 berikut merupakan hasil dari eksperimen prediksi wisatawan mancanegara dengan menggunakan model neural network.

Tabel 6.4. Perbandingan Kinerja prediksi menggunakan Model Neural Network

Model	MSE	RMSE
NN(12-2-1)	0.01904	0.138
NN(12-3-1)	0.02190	0.148
NN(12-5-1)	0.01613	0.127
NN(12-7-1)	0.02103	0.145
NN(12-8-1)	0.02434	0.156
NN(12-5-5-1)	0.01769	0.133
NN(12-5-7-1)	0.01823	0.135
NN(12-5-9-1)	0.01638	0.128
NN(12-5-11-1)	0.01904	0.138
NN(12-5-13-1)	0.01988	0.141

Berdasarkan Tabel 6.4, menunjukkan bahwa model Neural Network, yaitu NN(12-5-1) memiliki nilai RMSE terkecil. Ini menunjukkan bahwa model NN(12-5-1) adalah yang terbaik.

Penulis juga melakukan eksperimen lain dengan menggunakan parameter yang lain dari Neural network, yaitu dengan masukan/ input 2 periode dengan parameter iterasi=10.000, learning rate=0.05., momentum=0.5, jumlah

neuron di hidden layer bervariasi, dan jumlah hidden layer sebanyak 1 layer dan activation function hyperbolic tangen. Tabel 6.5, menunjukkan hasil kinerja model neural network dengan parameter tersebut di atas.

Tabel 5.6 Kinerja prediksi menggunakan Model Neural Network dengan input =2

Model	MSE	RMSE
NN(2-3-1)	0.01261	0.11229
NN(2-4-1)	0.01192	0.10916
NN(2-5-1)	0.01438	0.11992
NN(2-6-1)	0.01446	0.12026
NN(2-7-1)	0.01427	0.11944
NN(2-8-1)	0.014622	0.12092

Dari Tabel 6.5, terlihat bahwa konfigurasi dengan input neural network sebanyak 2 neuron memberikan kinerja yang lebih baik daripada Neural network dengan input 12 neuron.

6.4 Perbandingan model Prediksi

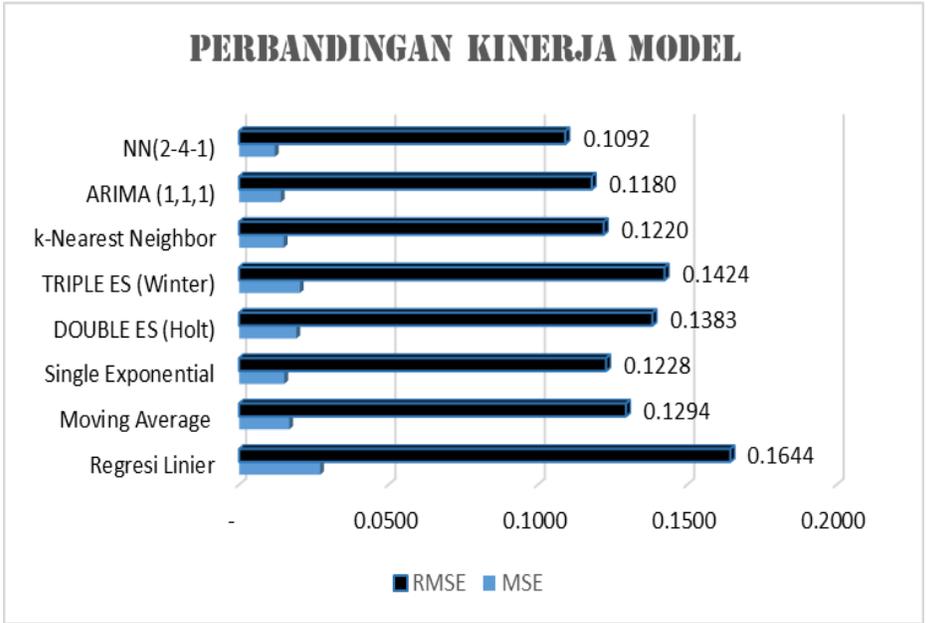
Berdasarkan hasil kinerja model regresi linier dan hasil-hasil dari model moving average, single exponential

smoothing, double exponential smoothing dan k-nearest neighbor serta model neural network pada Tabel 6.1 sampai dengan tabel 6.5, maka dapat dibandingkan hasil kinerja model-model tersebut.

Tabel 6.6. Perbandingan Kinerja Model/metode prediksi wisatawan

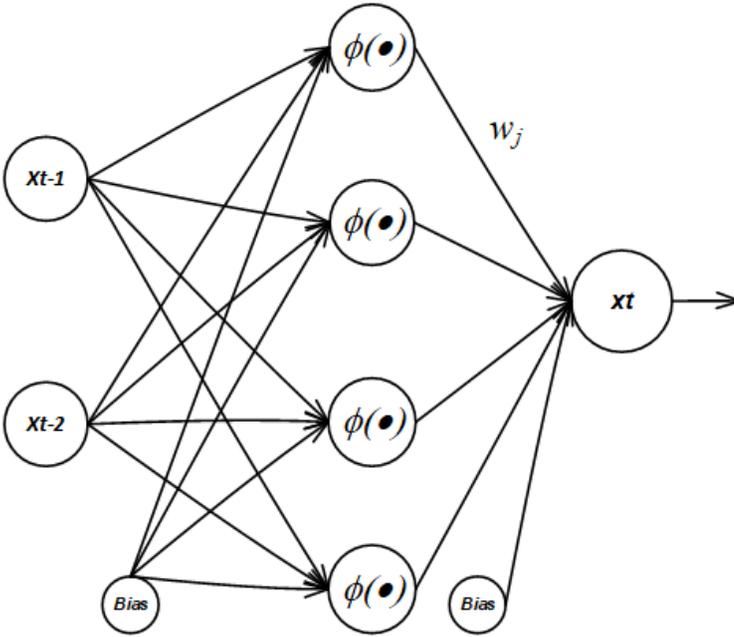
Model	MSE	RMSE
Regresi Linier	0.02706	0.16440
Moving Average	0.01675	0.12943
Single Exponential	0.01508	0.12279
DOUBLE ES (Holt)	0.01913	0.13830
TRIPLE ES (Winter)	0.02027	0.14237
k-Nearest Neighbor	0.01488	0.12200
NN(2-4-1)	0.01192	0.10916

Untuk lebih jelas dalam perbandingan kinerja model, Gambar 6.1 menunjukkan perbandingan nilai MSE dan RMSE dari model/ metode Regresi linier (trend), moving average, Single exponential Smoothing, Double exponential Smoothing, Triple exponential Smoothing, ARIMA, k-NN dan Neural Network.



Gambar 6.1. Perbandingan kinerja model

Dari Tabel 6.6 dan Gambar 6.1 terlihat bahwa nilai kinerja RMSE dan MSE dari model neural network yaitu NN (2-4-1) memiliki nilai RMSE yang paling kecil, sehingga model ini merupakan model yang terbaik yang dapat digunakan untuk memprediksi pariwisata mancanegara Jawa Tengah. Model NN (2-4-1) ditunjukkan pada Gambar 6.2.



Gambar 6.2. Model terbaik Neural Network NN(2-4-1)

6.5 Model Dual Neural Network

Dari hasil eksperimen menunjukkan bahwa model Neural Network dengan arsitektur seperti pada gambar 5, merupakan model yang cocok untuk prediksi wisatawan. Hal ini ditunjukkan dengan nilai paling nilai MSE dan RMSE jika dibandingkan dengan model/ metode lainnya, seperti moving average, single exponential smoothing, double exponential smoothing, triple ES dan k-nearest neighbor.

Seperti metode yang diusulkan, prediksi metode neural network digunakan untuk menemukan residual atau error. Selanjutnya nilai error ini digunakan sebagai input untuk neural network kedua. Hasil prediksi error atau residual ini, selanjutnya digunakan untuk memprediksi errornya. Selanjutnya hasil penjumlahan prediksi dengan neural network pertama dan hasil prediksi dengan neural ke dua dijumlahkan hasilnya.

Tabel 6.7 Data aktual, prediksi dan residual

No	Actual	Prediksi	Residual
1	0.0058	0.1679	-0.1621
2	0.1776	0.1715	0.0061
3	0.213	0.1979	0.0151
4	0.1423	0.2558	-0.1135
5	0.2771	0.2152	0.0619
6	0.4927	0.3395	0.1531
7	0.3621	0.5348	-0.1727
8	0.3895	0.3645	0.0251
9	0.2905	0.338	-0.0475
10	0.2577	0.3016	-0.0439

No	Actual	Prediksi	Residual
11	0.2386	0.2611	-0.0225
12	0.146	0.2509	-0.1049
13	0.2659	0.221	0.0448
14	0.3299	0.3281	0.0019
15	0.406	0.3141	0.0919
...
274	0.3088	0.274	0.0348

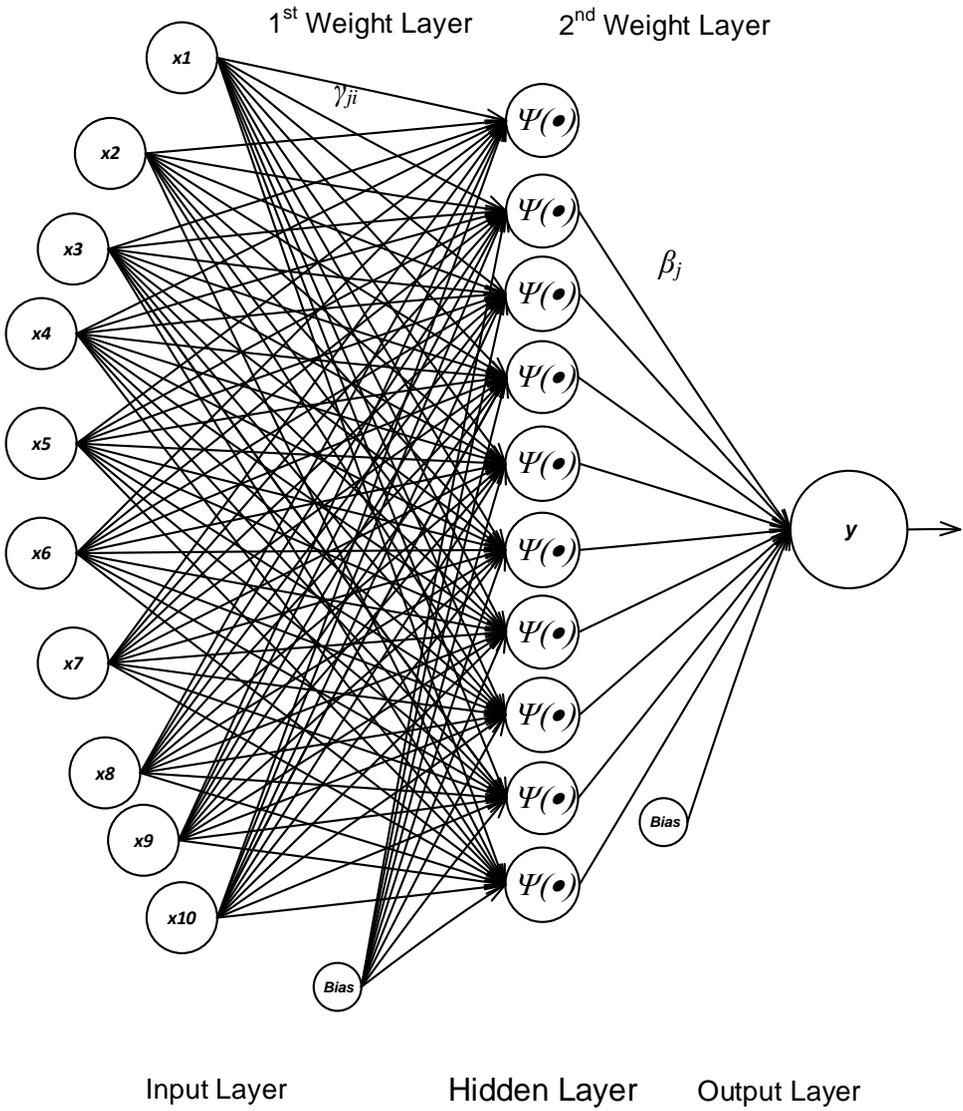
Data residual pada tabel 5.7 selanjutnya digunakan sebagai input neural network yang ke dua. Selanjutnya hasil perbandingan RMSE dan MSE model neural network yang ke-dua ditunjukkan pada tabel berikut ini.

Tabel 6.8 Perbandingan MSE dan RMSE Neural Network ke-

No.	Model	MSE	RMSE	Activation Function
1	NN(2-9-1)	0.0113	0.1064	Hyperbolic Tangent
2	NN(2-7-1)	0.0113	0.1064	Hyperbolic Tangent
3	NN(2-5-1)	0.0113	0.1062	Hyperbolic Tangent

No.	Model	MSE	RMSE	Activation Function
4	NN(2-7-1)	0.0112	0.1057	Bipolar Sigmoid
5	NN(5-10-1)	0.0095	0.0977	BipolarSigmoid
6	NN(7-10-1)	0.0102	0.1012	Hyperbolic Tangent
7	NN(9-10-1)	0.0110	0.1049	Hyperbolic Tangent
8	NN(7-10-1)	0.0085	0.0921	BipolarSigmoid
9	NN(10-10-1)	0.0076	0.0873	BipolarSigmoid

Berdasarkan Tabel 5.8 terlihat bahwa nilai NN(10-10-1) memiliki nilai RMSE dan MSE yang paling kecil. Ini menunjukkan bahwa model NN(10-10-1) merupakan nilai terbaik jika dibandingkan dengan model neural network yang lain. Arsitektur Neural Network NN(10-10-1) ditunjukkan pada gambar 6.



Gambar 6.3 Model terbaik Neural Network NN(10-10-1) dengan input residual

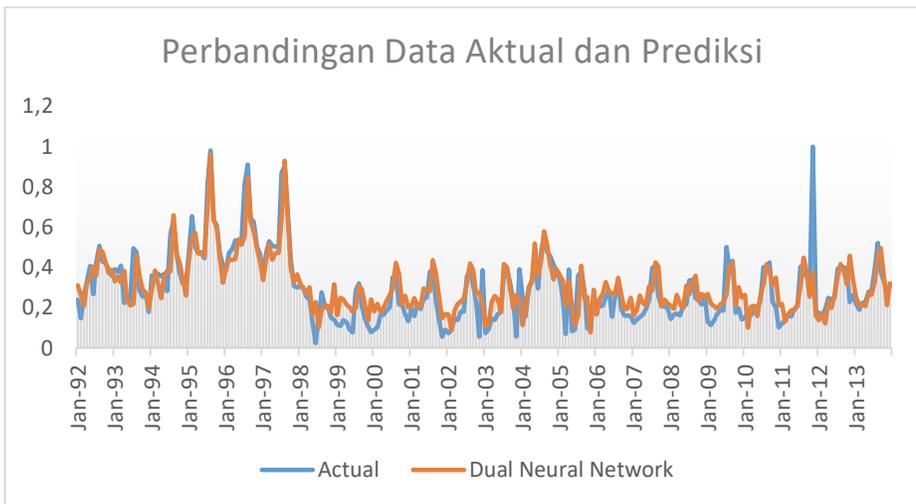
Selanjutnya hasil penggabungan Dual Neural Network NN(2-4-1) dan NN(10-10-1) menghasilkan prediksi wisatawan. Contoh perbandingan nilai aktual dan hasil prediksi Dual Neural Network ditunjukkan pada Tabel 5.9.

Tabel 6.9 Hasil Prediksi menggunakan Dual Neural Network
(contoh sebagian)

No	Time	Actual	NN (2-4-1)	NN(10-10-1)	DNN
1	Jan-92	0.2386	0.2611	0.0503	0.3114
2	Feb-92	0.1460	0.2509	0.0137	0.2646
3	Mar-92	0.2659	0.2210	-0.0118	0.2092
4	Apr-92	0.3299	0.3281	-0.0053	0.3228
5	May-92	0.4060	0.3141	0.0325	0.3466
6	Jun-92	0.2667	0.3598	0.0429	0.4027
7	Jul-92	0.4229	0.3021	0.0562	0.3583
8	Aug-92	0.5062	0.4394	0.0497	0.4891
9	Sep-92	0.4281	0.4390	0.0378	0.4768
10	Oct-92	0.4212	0.3964	0.0261	0.4225
11	Nov-92	0.3901	0.3706	0.0009	0.3715
12	Dec-92	0.3569	0.3518	0.0356	0.3874
13	Jan-93	0.3909	0.3254	0.0050	0.3304
14	Feb-93	0.3778	0.3390	0.0159	0.3549

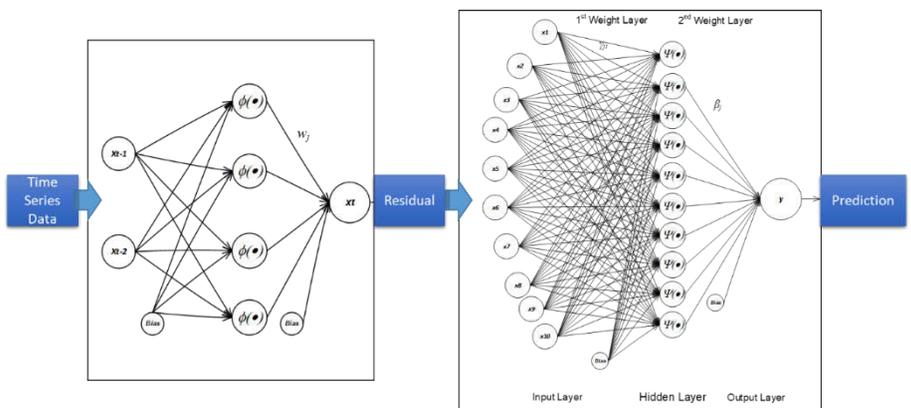
15	Mar-93	0.4084	0.3357	-0.0120	0.3237
16	Apr-93	0.2231	0.3523	0.0301	0.3824
17	May-93	0.2374	0.2927	-0.0574	0.2353
18	Jun-93	0.2367	0.2552	-0.0454	0.2098
19	Jul-93	0.4943	0.2515	-0.0330	0.2185
20	Aug-93	0.4727	0.5273	-0.0663	0.4610

Selanjutnya perbandingan data aktual dan data hasil prediksi menggunakan model Dual Neural Network ditunjukkan pada gambar 7. Dari Gambar 7, terlihat bahwa grafik antara data aktual dan data prediksi menggunakan Dual Neural Network menunjukkan sangat dekat.



Gambar 6.4 Perbandingan data aktual dan data hasil prediksi menggunakan model Dual Neural Network

Kombinasi terbaik model Dual Neural Network adalah NN(2-4-1) dan NN(10-10-1). Gambar 8, menunjukkan Arsitektur Neural Network NN(2-4-1) digunakan untuk prediksi awal dan NN(10-10-1) digunakan untuk memprediksi residual dari model Hybrid DNN.



Gambar 6.5 Arsitektur Neural Network NN(2-4-1) dan NN(10-10-1)

Kinerja model Hybrid DNN yaitu MSE dan RMSE adalah masing-masing 0.00761 dan 0.0873. Apabila dibandingkan dengan Tabel 6.8, maka model Hybrid DNN memberikan hasil yang terbaik. Tabel 6.10 berikut merupakan prosentasi

64

kenaikan kinerja model Hybrid DNN terhadap model-model lainnya.

Tabel 6.10. Kenaikan Kinerja Model Hybrid DNN terhadap model lain

Model	Kinerja		Improvement Kinerja (%)	
	MSE	RMSE	MSE	RMSE
Regresi Linier	0.02706	0.1644	71.87731	47.080292
Moving Average	0.01675	0.12943	54.56716	32.7821989
Single Exponential	0.01508	0.12279	49.53581	29.1473247
DOUBLE ES (Holt)	0.01913	0.1383	60.21955	37.0932755
TRIPLE ES (Winter)	0.02027	0.14237	62.45683	38.8916204
k-Nearest Neighbor	0.01488	0.122	48.85753	28.6885246
NN(2-4-1)	0.01186	0.1089	35.83474	20.1101928
Hybrid DNN	0.00761	0.087	0	0

6.6 Pengembangan Dual Neural Network berbasis PSO untuk Prediksi Wisatawan

Pada tahun ke-II ini, akan dikembangkan Pengembangan Dual Neural Network berbasis PSO untuk Prediksi Wisatawan Mancanegara. Seperti telah disajikan dalam Gambar 7. model DNN terbentuk dari Neural Network NN(2-4-1) dan NN(10-10-1). Model Hybrid DNN

memiliki kinerja yang terbaik dengan telah ditunjukkannya memiliki nilai MSE dan RMSE paling kecil. Selanjutnya peneliti mengembangkan model dual-neural network berbasis *Particle Swam Optimization* untuk meningkatkan kinerja modelnya. Pada eksperimen model pengembangan model dual-neural network berbasis *Particle Swam Optimization*, peneliti menggunakan data jumlah wisatawan Jawa Tengah untuk membuktikan model yang diusulkan.

Pada percobaan ini, peneliti menggunakan data wisatawan mancanegara di Jawa Tengah. Setelah melalui pengolahan data awal, selanjutnya data dibagi menjadi dua bagian yaitu data training dan data testing. Dalam penelitian ini, data 90% digunakan untuk training dan 10% digunakan untuk testing. Peneliti menggunakan model Neural network yang dioptimisasi dengan menggunakan *Particle Swam Optimization*. Dalam percobaan ini, peneliti menggunakan nilai epoch, Learning rate dan momentum yang berberda-beda. Berikut ini merupakan hasil kinerja model Neural Network berbasis PSO, seperti ditunjukkan pada Tabel 6.11

Tabel 6.11. Kinerja Model Neural Network berbasis PSO

Model	Parameter			RMSE
	Epoch	Learning Rate	Momentum	
Neural Network	5000	0.3	0.2	0.075
Neural Network	5000	0.2	0.2	0.067
Neural Network	10000	0.05	0.5	0.065
Neural Network	5000	0.1	0.2	0.062

Dari Tabel 6.11, terlihat bahwa kinerja terbaik diperoleh dari model Neural network dengan parameter epoch=5000, Learning rate= 0.3 dan momentum= 0.2. Sedangkan hasil dari optimalisasi PSO, hasil experiment menghasilkan bobot variabel x_{t-1} dan x_{t-2} , yaitu $x_{t-2} = 0.7566601776811037$ dan $x_{t-1} = 0.9419446754852374$. Hasil prediksi menggunakan Neural network berbasis PSO ditunjukkan pada Tabel 5.10 berikut ini.

Tabel 5.10. Hasil Prediksi menggunakan Neural Network berbasis PSO

Bulan	Actual	NN+PSO	Residual
Mar-91	0.005810	0.092626	-0.086816
Apr-91	0.177550	0.094099	0.083451
May-91	0.213020	0.172865	0.040155
Jun-91	0.142290	0.199956	-0.057666
Jul-91	0.277060	0.157370	0.119690

Bulan	Actual	NN+PSO	Residual
Aug-91	0.492680	0.246702	0.245978
Sep-91	0.362130	0.436279	-0.074149
Oct-91	0.389530	0.328516	0.061014
Nov-91	0.290500	0.348802	-0.058302
Dec-91	0.257690	0.264055	-0.006365
Jan-92	0.238590	0.235304	0.003286
Feb-92	0.145970	0.220138	-0.074168
Mar-92	0.265870	0.160104	0.105766
Apr-92	0.329940	0.237966	0.091974
May-92	0.406040	0.293660	0.112380
...			
Dec-13	0.308770	0.244379	0.064391

Data residual pada tabel 5.10 selanjutnya digunakan sebagai input neural network yang ke dua. Peneliti telah melakukan eksperimen dengan berbagai macam konfigurasi neural-network dengan input residual ini. Hasil Neural network ke-2 adalah NN(12-10-1). Selanjutnya, hasil prediksi Neural network berbasis PSO dan Neural network ke-2 dengan input residual dijumlahkan yang merupakan hasil prediksi dari model DNN berbasis PSO. Hasil DNN berbasis PSO ditunjukkan pada Tabel 5.11.

Tabel 5.11. Hasil Prediksi menggunakan Dual Neural Network
(DNN) berbasis PSO

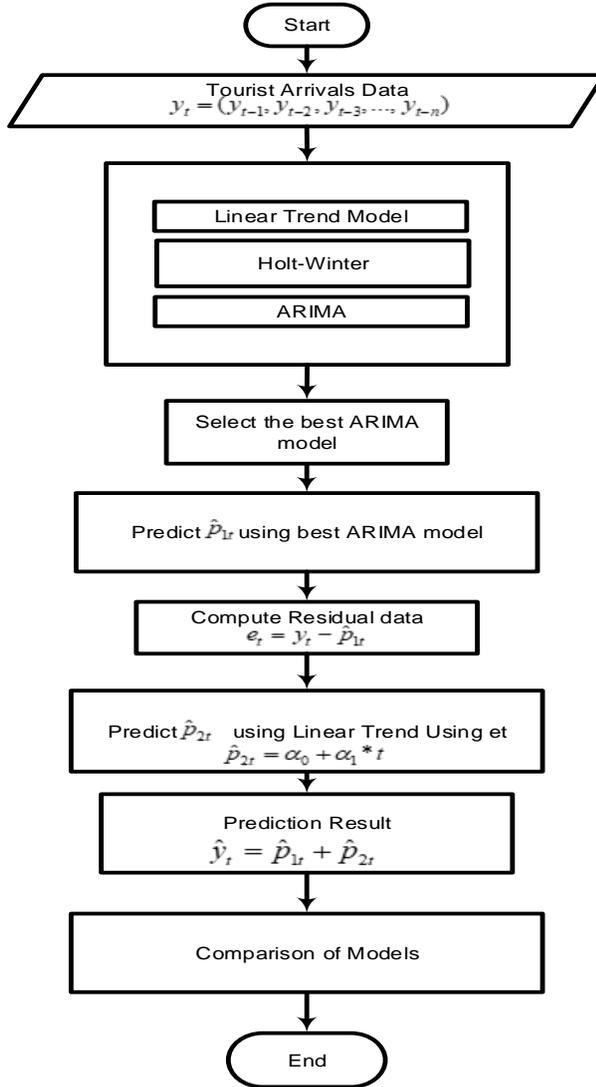
Month	Actual	NN(2-4-1) PSO	NN(12-10-1)	DNN+PSO
Mar-92	0.26587	0.160104475	0.0312	0.19130447
Apr-92	0.32994	0.237965932	0.0262	0.26416593
May-92	0.40604	0.293660022	0.0252	0.31886002
Jun-92	0.2667	0.362622245	-0.042	0.32062224
Jul-92	0.42288	0.245637177	0.0961	0.34173718
Aug-92	0.50623	0.375879748	0.0951	0.47097975
Sep-92	0.42811	0.451917696	-0.0664	0.3855177
Oct-92	0.42122	0.387844037	0.0076	0.39544404
Nov-92	0.39008	0.379106169	-0.0197	0.35940617
Dec-92	0.35689	0.351078578	0.0325	0.38357858
Jan-93	0.39087	0.320624346	0.0526	0.37322435
Feb-93	0.37779	0.349846504	0.0034	0.3532465
Mar-93	0.40842	0.339180312	0.0304	0.36958031
Apr-93	0.22311	0.366138764	0.0879	0.45403876
May-93	0.23742	0.213509147	0.0737	0.28720915
...				
Dec-13	0.30877	0.244379038	0.0864	0.33077904

Hasil kinerja dari model DNN berbasis PSO diperoleh $MSE = 0.00558052$ dan $RMSE = 0.07470285$. Dari Tabel 5.8 diperoleh bahwa kinerja model DNN yaitu $RMSE = 0.087$. Ini menunjukkan bahwa nilai $RMSE$ dari DNN berbasis PSO lebih kecil daripada model DNN. Sehingga dapat disimpulkan bahwa model DNN berbasis PSO lebih baik dari model DNN dan model-model yang lain seperti yang tersaji pada tabel 5.8.

6.6. Pengembangan Model Hybrid Kombinasi ARIMA dan model Linear Trend

Peneliti juga telah mengembangkan model Hybrid kombinasi ARIMA dan model Linear Trend untuk prediksi kedatangan turis di Surakarta. Untuk menguji model, penelitian ini menggunakan data set yaitu data rentet waktu kedatangan turis di Surakarta, Central Java, Indonesia pada periode 1991 sampai dengan 2013. Data kedatangan turis mencakup data bulanan kedatangan turis selama January 1991 sampai December 2013. Data rentet waktu kedatangan turis ditunjukkan pada Tabel 3.2.

Semua prediksi rentet waktu dihitung dengan model ARIMA, linear trend, Holt-Winter triple exponential smoothing dan hybrid model mengkombinasikan ARIMA dan linear trend model. Metode yang diusulkan digunakan untuk prediksi kedatangan turis. Model hybrid yang diusulkan digambarkan pada gambar 6.6 berikut ini:



Gambar 6.6. Metode hybrid yang diusulkan untuk prediksi kedatangan turis di Surakarta

Metode hybrid yang diusulkan dapat dilakukan dengan langkah demi langkah yang dapat dijelaskan sebagai berikut:

STEP 1 : Pada langkah ini, dikumpulkan data rentet waktu kedatangan turis yang telah ditunjukkan pada Tabel 1.

STEP 2 : Pada langkah 2, percobaan-percobaan menggunakan model ARIMA (p, d, q) dengan nilai parameter yang berbeda pada nilai $p, d,$ dan q , *Linear trend model, Holt-Winter triple exponential smoothing.*

STEP 3 : Kami juga melakukan perhitungan dengan menggunakan model yang diusulkan yaitu model hybrid yang mengkombinasikan ARIMA terbaik dan model *linear trend*. Model ARIMA menggunakan data aktual kedatangan turis sebagai input, dan model *Linear trend* menggunakan data residual sebagai input. Hasil dari hybrid model merupakan jumlah total dari prediksi yang dihasilkan menggunakan model terbaik ARIMA dan hasil prediksi menggunakan model *linear trend*.

STEP 4 : Pada langkah ke-4, perbandingan kinerja akurasi dari model-model ARIMA terbaik, *Linear trend*, *Holt-Winter triple exponential smoothing* dan model hybrid mengkombinasikan ARIMA terbaik dan model *Linear trend* dilakukan. Model terbaik yang menghasilkan akurasi kinerja terbaik selanjutnya digunakan untuk memprediksi kedatangan turis.

Kami menggunakan empat model prediksi dalam penelitian ini. Model-model tersebut adalah ARIMA, model *Linear Trend*, *Holt-Winter triple exponential smoothing* dan model hybrid mengkombinasikan ARIMA dan model *Linear Trend*. Hasil-hasil yang diperoleh didiskusikan dibawah ini.

6.2. ARIMA model untuk prediksi kedatangan turis

Model ARIMA digunakan untuk prediksi kedatangan turis. Kami melakukan percobaan menggunakan model ARIMA (p, d, q) dengan nilai parameter-parameter yang

berbeda. Untuk model ARIMA (p, d, q), kami menggunakan parameter p= 0, 1, 2, d =0,1 dan q=0, 1, 2. Hasil dari prediksi kedatangan turis dan nilai RMSE menggunakan model ARIMA ditunjukkan pada Tabel 5.12.

Tabel 5.12. Hasil Prediksi kedatangan turis dan RMSE dengan ARIMA

Month	Actual	ARIMA	ARIMA	ARIMA	ARIMA	ARIMA	ARIMA
	Data	(1,0,1)	(2,1,2)	(1,0,2)	(1,1,1)	(1,1,2)	(2,1,1)
Feb-91	2,140.00	2,452.44	2,584.54	2,452.04	2,584.59	2,584.63	2,584.65
Mar-91	2,008.00	2,189.64	2,253.48	2,188.67	2,247.18	2,243.33	2,242.01
Apr-91	1,926.00	2,051.21	2,123.54	2,161.79	2,130.00	2,131.25	2,131.51
May-91	2,368.00	1,969.56	2,052.83	2,075.87	2,051.22	2,052.76	2,053.32
Jun-91	3,398.00	2,229.90	2,307.74	2,304.13	2,316.59	2,321.62	2,323.45
Jul-91	3,647.00	2,934.58	2,972.91	2,805.03	2,974.87	2,979.89	2,981.92
Aug-91	4,407.00	3,244.50	3,196.42	2,918.01	3,183.64	3,176.70	3,174.62
Sep-91	3,402.00	3,790.08	3,703.38	3,437.12	3,704.68	3,700.93	3,699.52
Oct-91	3,661.00	3,276.40	3,205.28	2,949.34	3,174.93	3,156.93	3,150.65
Nov-91	2,694.00	3,327.65	3,336.36	3,313.83	3,353.85	3,353.44	3,352.62
Dec-91	2,909.00	2,730.37	2,834.48	2,754.31	2,807.84	2,798.66	2,795.43
...
13-Dec	1,686.00	1,785.88	1,902.85	1,971.09	1,908.11	1,909.16	1,909.49
RMSE		875.557	849.626	862.425	849.918	849.813	849.771

Pada tabel 5.12 menunjukkan bahwa nilai RMSE terkecil diperoleh untuk model ARIMA(2,1,2). Kami dapat menyimpulkan bahwa model ARIMA(2,1,2) memberikan model terbaik menggunakan using model ARIMA.

6.3. Model Linear trend untuk prediksi kedatangan turis

Nilai prediksi kedatangan turis menggunakan model linear trend dihitung dengan menggunakan rumus sebagai berikut:

$$\hat{Y}_t = \alpha_0 + \alpha_1 t$$

Dimana parameter a_0 adalah constant, a_1 adalah perubahan rata-rata dari satu periode ke periode berikutnya, dan t adalah nilai unit waktu. Setelah kami mengimplementasikan linear trend model menggunakan data kedatangan turis diperoleh model linear trend sebagai berikut:

$$\hat{Y}_t = 2873.4 - 6.0869 * t$$

Hasil-hasil prediksi dan nilai RMSE menggunakan model linear trend diperlihatkan pada tabel 5.13 berikut ini.

Tabel 5. 13. Hasil Prediksi dan RMSE menggunakan model linear trend

Month	actual	Linear Trend
Jan-91	2588	2867.2683
Feb-91	2140	2861.1814
Mar-91	2008	2855.0945

Apr-91	1926	2849.0076
May-91	2368	2842.9208
Jun-91	3398	2836.8339
Jul-91	3647	2830.747
Aug-91	4407	2824.6601
Sep-91	3402	2818.5732
Oct-91	3661	2812.4864
Nov-91	2694	2806.3995
Dec-91	2909	2800.3126
....		
Dec-13	1686	1193.3767
RMSE		1,275.25

6.4. Metode Holt-Winter triple exponential smoothing untuk prediksi kedatangan turis

Kami juga mengimplementasikan metode *Holt-Winter triple exponential smoothing* untuk prediksi kedatangan turis. Hasil-hasil akurasi kinerja menggunakan model *Holt-Winter triple exponential smoothing* ditunjukkan pada Table 3. Kami menghitung model *Holt-Winter triple exponential smoothing* dengan smoothing constants yang berbeda-beda pada parameter α , γ dan δ . Akurasi kinerja RMSE menggunakan

metode *Holt-Winter triple exponential smoothing* diperlihatkan pada tabel 5.14 berikut ini:

Tabel 5.14. Hasil MSE dan RMSE menggunakan metode Holt-Winter triple exponential smoothing

MODEL	Smoothing Constants			PERFORMANCE	
	α	γ	δ	MSE	RMSE
Holt-Winter triple exponential smoothing	0.20	0.20	0.20	1,131,557.73	1063.75
	0.10	0.10	0.10	4,366,350.71	2089.58
	0.70	0.10	0.10	923,822.41	961.16
	0.70	0.10	0.20	931,259.26	965.02
	0.80	0.10	0.10	935,263.50	967.09
	0.70	0.10	0.30	938,191.32	968.60
	0.80	0.10	0.20	941,700.78	970.41
	0.60	0.10	0.20	941,418.46	970.27
	0.70	0.10	0.30	945,823.08	972.53
	0.80	0.10	0.20	946,756.93	973.01

Dari Tabel 4 diperlihatkan bahwa nilai RMSE terkecil diperoleh model Holt-Winter triple exponential smoothing dengan nilai *smoothing constants* adalah $\alpha=0.7$, $\gamma=0.1$ dan $\delta=0.1$.

6.5. Hybrid model combining ARIMA and Linear trend untuk prediksi kedatangan turis

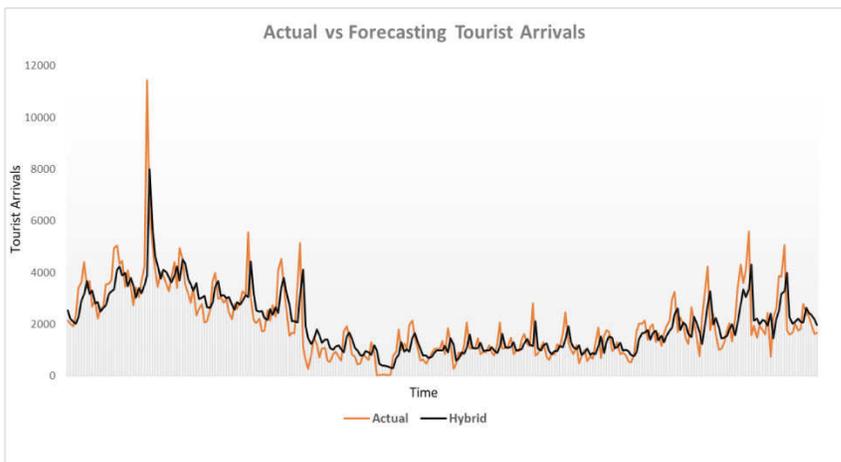
Pada Tabel 5.12 telah ditunjukkan bahwa nilai RMSE terkecil diperoleh pada model ARIMA(2,1,2). Model terbaik

ARIMA(2,1,2) ini selanjutnya digunakan untuk membangun hybrid model. Berdasarkan metode yang diusulkan dan telah ditunjukkan pada Gambar 8, model hybrid mengkombinasikan ARIMA(2,1,2) dan model linear trend digunakan untuk prediksi kedatangan turis. Hasil akurasi kinerja pada prediksi kedatangan turis menggunakan model hybrid ditunjukkan pada Tabel 5.15 berikut ini:

Tabel 5.15 Hasil Prediksi dan RMSE menggunakan Hybrid model

Month	Actual	ARIMA (2,1,2)	Linear Trend	Hybrid
				ARIMA + Linear Trend
Feb-91	2140	2584.54	-39.62	2544.93
Mar-91	2008	2253.48	-39.26	2214.22
Apr-91	1926	2123.54	-38.90	2084.64
May-91	2368	2052.83	-38.55	2014.28
Jun-91	3398	2307.74	-38.19	2269.55
Jul-91	3647	2972.91	-37.84	2935.07
Aug-91	4407	3196.42	-37.48	3158.94
Sep-91	3402	3703.38	-37.13	3666.25
Oct-91	3661	3205.28	-36.77	3168.51
Nov-91	2694	3336.36	-36.41	3299.95
Dec-91	2909	2834.48	-36.06	2798.42
...				
Dec-13	1686	1902.85	57.83	1960.68
	RMSE			849.107

Perbandingan secara grafik dari nilai aktual dan nilai prediksi menggunakan model hybrid mengkombinasikan ARIMA(2,1,2) dan model Linear trend ditunjukkan pada gambar 6.7 sebagai berikut:



Gambar 6.7. Perbandingan nilai aktual dan prediksi kedatangan turis

Gambar perbandingan nilai aktual dan prediksi kedatangan turis menunjukkan bahwa nilai prediksi kedatangan turis menggunakan model hybrid kombinasi ARIMA (2,1,2) dan model linear trend adalah sangat saling berdekatan dengan nilai aktual. Ini menunjukkan bahwa

secara grafik model hybrid yang diusulkan baik digunakan untuk prediksi kedatangan turis.

6.6. Perbandingan Model

Perbandingan nilai RMSE yang diperoleh menggunakan model ARIMA terbaik, model Linear trend, Holt-Winter triple exponential smoothing dan model Hybrid mengkombinasikan ARIMA(2,1,2) dan model linear trend ditunjukkan pada Tabel 5.16.

Tabel 5.16. .Perbandingan Kinerja untuk prediksi kedatangan turis

NO	MODELS	RMSE
1	The Best ARIMA	849.626
2	The best Holt-Winter triple exponential smoothing	961.160
3	Linear Trend	1,275.25
4	Hybrid (ARIMA (2,1,2)+Linear Trend)	849.107

Dari Tabel 5.16 menunjukkan bahwa model hybrid mengkombinasikan ARIMA (2,1,2) dan model linear trend memberikan nilai RMSE terkecil. Ini menunjukkan bahwa model hybrid yang diusulkan memberikan hasil terbaik dibandingkan dengan semua model-model yang lain.