



TUGAS AKHIR - SS141501

**PERBANDINGAN MODEL ARIMA DENGAN MODEL
RECURRENT ARTIFICIAL NEURAL NETWORK DALAM
MEMPREDIKSI JUMLAH WISATAWAN ASING YANG
DATANG KE PROVINSI BALI**

I PUTU PRASETYA WIKANTARA
NRP 1310 100 040

Dosen Pembimbing
Dr. Brodjol Sutijo Suprih Ulama, M.Si.

JURUSAN STATISTIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2016

Halaman ini sengaja dikosongkan



FINAL PROJECT - SS141501

COMPARISON BETWEEN ARIMA MODEL AND RECURRENT ARTIFICIAL NEURAL NETWORK ON FORECASTING FOREIGN TOURIST ARRIVAL IN BALI PROVINCE

I PUTU PRASETYA WIKANTARA
NRP 1310 100 040

Supervisor
Dr. Brodjol Sutijo Suprih Ulama, M.Si.

DEPARTMENT OF STATISTICS
Faculty of Mathematics and Natural Sciences
Institut Teknologi Sepuluh Nopember
Surabaya 2016

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN

PERBANDINGAN MODEL ARIMA DENGAN MODEL *RECURRENT ARTIFICIAL NEURAL NETWORK* DALAM MEMPREDIKSI JUMLAH WISATAWAN ASING YANG DATANG KE PROVINSI BALI

TUGAS AKHIR


Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

Program Studi S-1 Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

I PUTU PRASETYA WIKANTARA
NRP. 1310 100 040

Disetujui oleh Pembimbing Tugas Akhir :


Dr. Brodjol Sutijo Suprih Ulama, M.Si.
NIP. 19660125 199 002 1 001

Mengetahui
Ketua Jurusan Statistika FMIPA-ITS


Dr. Suhartono, S.Si, M.Sc
NIP. 19710929 199 512 1 001

SURABAYA, JANUARI 2016





DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
DAFTAR LAMPIRAN	xix
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	4
1.5 Batasan Masalah	4
BAB II TINJAUAN PUSTAKA	
2.1 Analisis Deret Waktu (<i>Time Series</i>).....	5
2.2 Uji Nonlinearitas Terasvirta.....	5
2.3 Model <i>Autoregressive Integrated Moving Average</i> (<i>ARIMA</i>).....	5
2.3.1 Model <i>ARIMA</i> Non Musiman	6
2.3.2 Model <i>ARIMA</i> Musiman	6
2.3.3 Model Multiplikatif <i>ARIMA</i> Musiman.....	7
2.4 Identifikasi Model	7
2.4.1 Stasioneritas	7
2.4.2 <i>Autocorrelation Function</i> (<i>ACF</i>)	8
2.4.3 <i>Partial Autocorrelation Function</i> (<i>PACF</i>)....	9
2.5 Identifikasi Model <i>ARIMA</i>	9
2.6 Penaksiran Parameter Model <i>ARIMA</i>	10
2.7 Pengujian Signifikansi Parameter	12

2.8	Cek Diagnosa	12
2.9	<i>Artificial Neural Network</i>	14
2.9.1	Arsitektur ANN	14
2.9.2	<i>Feed Forward Neural Network</i>	16
2.9.3	<i>Elman Recurrent Neural Network</i>	17
2.10	Kriteria Kebaikan Model	19
BAB III METODOLOGI PENELITIAN		
3.1	Sumber Data dan Variabel Penelitian	21
3.2	Metode Analisis	21
3.3	Diagram Alir	23
BAB IV ANALISIS DAN PEMBAHASAN		
4.1	Analisis Deskriptif Jumlah Wisatawan Asing yang Datang ke Provinsi Bali.....	25
4.2	Uji Nonlinearitas Data Jumlah Wisatawan Asing yang Datang ke Provinsi Bali.....	26
4.3	Metode ARIMA	27
4.4	Metode Elman-Recurrent Neural Network	33
4.5	Perbandingan Model ARIMA dan Jaringan Elman- RNN	35
4.6	Peramalan Jumlah Kedatangan Wisatawan Asing yang Datang ke Bali.....	36
BAB V KESIMPULAN DAN SARAN		
5.1	Kesimpulan	39
5.2	Saran.....	39
DAFTAR PUSTAKA		41
LAMPIRAN		43
BIODATA PENULIS		47

DAFTAR TABEL

	Halaman
Tabel 2.1 Transformasi Box-Cox	7
Tabel 2.2 Bentuk ACF dan PACF untuk Identifikasi Model ARIMA Non Musiman	10
Tabel 2.3 Bentuk ACF dan PACF untuk Identifikasi Model ARIMA Musiman	10
Tabel 4.1 Statistik Deskriptif Kedatangan Wisatawan Asing Per Bulan	26
Tabel 4.2 Uji Nonlinearitas Terasvirta.....	27
Tabel 4.3 Uji Signifikansi Model ARIMA ([1,2,10,13],1,[1,11])(0,1,1) ₁₂	31
Tabel 4.4 Uji Signifikansi Model ARIMA (1,1,[1,11]) (0,1,1) ₁₂	32
Tabel 4.5 Uji <i>White Noise</i> Residual Model ARIMA (1,1,[1,11])(0,1,1) ₁₂	32
Tabel 4.6 Uji Kolmogorov-Smirnoff Residual Model ARIMA (1,1,[1,11])(0,1,1) ₁₂	33
Tabel 4.7 Kriteria Kebaikan Jaringan RNN.....	34
Tabel 4.8 Bias Input Jaringan (5,4,1).....	34
Tabel 4.9 Bobot Input Jaringan (5,4,1)	35
Tabel 4.10 Bobot <i>Hidden Layer</i> Jaringan (5,4,1)	35
Tabel 4.11 Kriteria Kebaikan <i>Out-Sample</i>	36
Tabel 4.12 Hasil Peramalan Kedatangan Wisatawan Asing Pada Tahun 2014	37




DAFTAR GAMBAR

		Halaman
Gambar 2.1	Arsitektur <i>Single Layer Perceptron</i>	15
Gambar 2.2	Arsitektur <i>Multilayer Perceptron</i>	16
Gambar 2.3	Arsitektur FFNN.....	17
Gambar 2.4	Arsitektur ERNN untuk Peramalan	18
Gambar 3.1	Diagram Alir Pemodelan ARIMA.....	23
Gambar 3.2	Diagram Alir Metode ANN	24
Gambar 4.1	Rata-Rata Kedatangan Wisatawan Asing Per Bulan.....	26
Gambar 4.2	Plot <i>Time Series</i> dari Data Kedatangan Wisatawan Asing Per Bulan	27
Gambar 4.3	Plot Box-Cox dari Data Kedatangan Wisatawan Asing Per Bulan.....	28
Gambar 4.4	Plot ACF dari Data Kedatangan Wisatawan Asing Per Bulan.....	28
Gambar 4.5	Plot <i>Time Series</i> dari Data <i>Differencing</i> 1 Lag....	29
Gambar 4.6	Plot ACF dari Data <i>Differencing</i> 1 Lag.....	29
Gambar 4.7	Plot <i>Time Series</i> dari Data <i>Differencing</i> 1 dan 12 Lag.....	30
Gambar 4.8	Plot ACF dari Data <i>Differencing</i> 1 dan 12 Lag ...	30
Gambar 4.9	Plot ACF dari Data <i>Differencing</i> 1 dan 12 Lag ...	31
Gambar 4.10	Perbandingan Out-Sample RNN(5,4,1), ARIMA(1,1,[1,11])(0,1,1) ₁₂ , dan Data Aktual	35
Gambar 4.11	Perbandingan Residual RNN(5,4,1) dan ARIMA(1,1,[1,11])(0,1,1) ₁₂	36



DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data Kedatangan Wisatawan Asing ke Provinsi Bali	43
Lampiran 2 Uji Terasvirta.....	44
Lampiran 3 Program <i>Recurrent Neural Network</i>	44
Lampiran 4 Hasil Output ARIMA pada SAS	45





KATA PENGANTAR

Puji syukur kehadiran Ida Sang Hyang Widhi Wasa, karena anugerah-Nya yang tiada hentinya penulis dapat menyelesaikan dengan baik Tugas Akhir yang berjudul

” PERBANDINGAN MODEL ARIMA DENGAN MODEL RECURRENT ARTIFICIAL NEURAL NETWORK DALAM MEMPREDIKSI JUMLAH WISATAWAN ASING YANG DATANG KE PROVINSI BALI”

Terselesaikannya Tugas Akhir ini, tidak terlepas dari dukungan berbagai pihak yang telah memberikan bimbingan dan bantuan pada penulis. Untuk itu pada kesempatan ini penulis mengucapkan terima kasih sedalam-dalamnya kepada :

1. Dr. Suhartono, S.Si, M.Sc., selaku Ketua Jurusan Statistika FMIPA ITS Jurusan Statistika FMIPA ITS yang telah memfasilitasi untuk kelancaran penyelesaian Tugas Akhir ini.
2. Pak Dr. Brodjol Sutijo Suprih Ulama, M.Si., selaku dosen pembimbing dan dosen wali yang dengan sabar telah membimbing penulis sejak awal masuk kuliah hingga penulis telah menyelesaikan studinya di jenjang S1 ini.
3. Seluruh staf pengajar dan karyawan Jurusan Statistika FMIPA ITS yang telah memberikan ilmu dan pengalaman selama masa perkuliahan.
4. Keluarga penulis, Bapak I Ketut Wiryadi, Ibu Ni Made Puri Adnyani, serta adik I Made Chandra Widyaputra atas segala doa, dukungan, dan motivasi yang sangat luar biasa besarnya sehingga penulis terus bersemangat hingga akhir penyelesaian tugas akhir ini.
5. Mita, Cokde, Weka, Dodi, Pasek, Vico, Andika, Pidada, dan teman-teman Rosalina lainnya yang selalu ada menemani penulis di saat senang maupun susah.
6. Dio, Novri, Bimo, Jalu, Zaka, Mitashi, Inayashi, dan teman-teman Statistika Angkatan 2010 lainnya yang tidak bosan-bosannya memotivasi penulis selama masa perkuliahan.
7. Serta pihak-pihak lain yang sangat berjasa dalam kelancaran proses penyelesaian tugas akhir ini.

Penulis mengharapkan Tugas Akhir ini dapat memberikan manfaat bagi pihak-pihak terkait terutama pembaca. Penulis menyadari bahwa Tugas Akhir ini masih jauh dari kesempurnaan. Oleh karena itu penulis sangat menerima apabila ada saran dan kritik yang sifatnya membangun guna perbaikan untuk penelitian-penelitian selanjutnya.

Surabaya, Januari 2016

Penulis


PERBANDINGAN MODEL ARIMA DENGAN MODEL RECURRENT ARTIFICIAL NEURAL NETWORK DALAM MEMPREDIKSI JUMLAH WISATAWAN ASING YANG DATANG KE PROVINSI BALI

Nama Mahasiswa : I Putu Prasetya Wikantara
NRP : 1310 100 040
Jurusan : Statistika FMIPA-ITS
Dosen Pembimbing : Dr. Brodjol Sutijo Suprih
Ulama, M.Si.

Abstrak

Pengembangan sektor pariwisata akan sangat mudah apabila perubahan permintaan yang akan datang pada pariwisata dapat diramalkan dari data-data masa lalu. Apabila pola kedatangan wisatawan diketahui, maka dapat dibentuk model yang dapat menggambarkan jumlah permintaan pada sektor pariwisata sehingga para pelaku bisnis maupun pemerintah dapat mengantisipasi tindakan ataupun keputusan yang harus diambil. Dalam penelitian ini akan diramalkan jumlah kedatangan wisatawan asing dengan menggunakan model ARIMA dan model Elman-RNN, mengingat bahwa pola kedatangan wisatawan tidak selalu linier. Data yang digunakan adalah data hasil survey Badan Pusat Statistika Bali. Data dibagi menjadi dua bagian yaitu data in-sample dan data out-sample. Data in-sample terdiri dari 84 observasi dan data out-sample terdiri dari 12 observasi. Pemilihan model terbaik menggunakan kriteria out-sample. Kriteria out-sample yang digunakan MAPE dan RMSE. Dari kedua model tersebut, model dari jaringan Elman-RNN adalah model terbaik dengan nilai MAPE dan RSME paling kecil, yaitu MAPE sebesar 5.41% dan RMSE sebesar 21884.

Kata Kunci: ANN, ARIMA, Elman-RNN, MAPE, pariwisata, RMSE, time series, wisatawan asing.



Halaman ini sengaja dikosongkan


COMPARISON BETWEEN ARIMA MODEL AND RECURRENT ARTIFICIAL NEURAL NETWORK ON FORECASTING FOREIGN TOURIST ARRIVAL IN BALI PROVINCE

Name of Student : I Putu Prasetya Wikantara
NRP : 1310 100 040
Department : Statistika FMIPA-ITS
Supervisor : Dr. Brodjol Sutijo Suprih
Ulama, M.Si.

Abstract

Tourism sector development will be really easy if demand changes could be forecasted from past data. If tourist arrival pattern is known, a model that shows tourism can be made so that government and entrepreneurs could anticipate and take action based on the forecast result. In this research, foreign tourist arrival will be forecasted using ARIMA model and Elman-RNN model, given that tourism arrival pattern is not always linear. Data used is survey data from Badan Pusat Statistika (BPS) Bali. Data will be split into 2 parts, which are data in-sample and data out-sample. Data in-sample consist of 84 observations and data out-sample consist of 12 observations. Best model selected using out-sample criteria. Out-sample criteria used is MAPE and RMSE. From both model, model from Elman-RNN is the best model with smallest MAPE and RMSE value, with MAPE 4.51% and RMSE 21884.

Keywords: ANN, ARIMA, Elman-RNN, MAPE, tourism, RMSE, time series, foreign tourist.



BAB I

PENDAHULUAN

1.1 Latar Belakang

Pulau Bali merupakan pulau yang banyak dikunjungi wisatawan karena memiliki pantai yang indah, pemandangan yang menakjubkan, souvenir yang menarik, serta adat dan kebudayaan yang menawan. Tentu saja tidak sedikit uang yang mengalir pada bidang pariwisata. Baik pemerintah dan masyarakat sekitar maupun pihak investor luar sadar akan potensi wisata dari Pulau Bali. Cho (2003) menyatakan bahwa peramalan memegang peranan penting dalam perencanaan wisata. Pengembangan sektor pariwisata akan sangat mudah apabila perubahan permintaan pada pariwisata dapat diramalkan dari data-data masa lalu. Apabila pola kedatangan wisatawan diketahui, maka para pelaku bisnis maupun pemerintah dapat mengantisipasi tindakan ataupun keputusan yang harus diambil. Untuk itu, akan dilakukan peramalan jumlah wisatawan asing yang datang ke Bali.

Beberapa metode peramalan yang dapat digunakan untuk memodelkan jumlah kedatangan wisatawan asing adalah ARIMA dan Artificial Neural Network (ANN). Pada ARIMA, model persamaan matematisnya diasumsikan sebagai fungsi linier dari beberapa pengamatan di masa lalu dan random *error*. Beberapa studi menunjukkan bahwa ketika model linier menghasilkan tingkat akurasi peramalan yang relatif kecil dan kesalahan dalam peramalan yang besar, kemungkinan model nonlinier mampu menjelaskan dan meramalkan time series dengan lebih baik dibandingkan dengan model linier (Zhang, 2003). *Artificial Neural Network* (ANN) merupakan salah satu contoh metode nonlinier yang mempunyai bentuk fungsional fleksibel dan mengandung beberapa parameter yang tidak dapat diinterpretasikan seperti pada model parametrik (Suhartono, 2007). ANN mampu melakukan pemodelan nonlinier tanpa lebih dahulu mengetahui hubungan antara variabel input dan output.

Oleh karena itu, ANN merupakan alat yang lebih umum dan fleksibel untuk peramalan data (Zhang, 2003).

Cho, dalam penelitiannya meramalkan jumlah kedatangan wisatawan dari berbagai Negara ke Hong Kong dengan menggunakan 3 metode, yaitu *exponential smoothing*, ARIMA, dan ANN. Hasil analisisnya menunjukkan bahwa ANN memberikan hasil terbaik dalam meramalkan jumlah kedatangan wisatawan. Burger dkk.(2001) juga melakukan peramalan terhadap kedatangan wisatawan di Durban, Afrika Selatan dengan beberapa metode, yaitu *naïve forecasting*, *single exponential smoothing*, *moving average*, *decomposition*, ARIMA, regresi ganda, serta ANN. Hasil penelitiannya menunjukkan bahwa metode ANN memberikan hasil yang terbaik.

Jumlah kedatangan wisatawan cenderung memiliki pola Moving Average (MA) pada hasil pemodelan ARIMA. Penelitian Saayman (2010) dalam meramalkan jumlah kedatangan wisatawan di Afrika Selatan, dan Widyawati (2013) dalam meramalkan jumlah penumpang pesawat di Bandar Udara Internasional Ngurah Rai menunjukkan bahwa dalam model ARIMA yang dihasilkan terdapat pola MA. Pada pemodelan ANN yang melibatkan komponen MA/error adalah jaringan *Elman Recurrent Neural Network* (RNN). Oleh karena itu, jaringan yang dipilih untuk peramalan adalah jaringan RNN. RNN menggunakan output jaringan sebagai input untuk mendapatkan output berikutnya, sehingga RNN dapat menjelaskan efek dari order AR dan MA secara bersamaan (Endharta dan Suhartono, 2009).

Pada penelitian ini, dilakukan pemodelan jumlah kedatangan wisatawan asing ke Bali dengan dua metode yang berbeda, yang pertama adalah dengan menggunakan model ARIMA dan yang kedua adalah dengan menggunakan model RNN. Dari dua metode tersebut dicari model terbaik. Tujuannya adalah peneliti ingin mengetahui hasil peramalan yang paling akurat dari kedua metode tersebut.

1.2 Rumusan Masalah

Data dari Bali Tourism Statistics yang diterbitkan oleh Dinas Pariwisata Daerah Bali selama 5 tahun hingga akhir tahun 2005 mengindikasikan adanya pergeseran yang signifikan dalam hal jumlah dan negara asal wisatawan yang berkunjung ke Bali (Suradnya, 2006). Pada tahun 2013 wisatawan yang datang ke Bali diramalkan akan anjlok. Hal ini dikarenakan akan terjadi persaingan tarif hotel dan pembangunan fasilitas pariwisata yang berlebihan (Sutiawan, 2012). Sulistyowati (2013) juga mengkhawatirkan bahwa jumlah wisatawan yang datang ke Bali akan rendah akibat persaingan harga tersebut, di mana tingkat hunian hotel turun sepanjang 2012 hingga berada di bawah 60 persen. Akan tetapi, pada kenyataannya data Badan Pusat Statistik (BPS) Bali menunjukkan adanya kenaikan kedatangan wisatawan asing dalam jangka waktu tahun 2006 sampai tahun 2013. Untuk mengetahui berapa jumlah wisatawan di masa yang akan datang dilakukan peramalan.

Banyak metode peramalan jumlah kedatangan wisatawan asing ke Bali, tetapi dalam penelitian ini akan dibandingkan 2 metode, yaitu metode ARIMA dan RNN. Permasalahannya mana metode yang terbaik untuk meramalkan jumlah kedatangan wisatawan asing yang datang ke Provinsi Bali di antara kedua metode tersebut?

1.3 Tujuan Penelitian

Berdasarkan pada latar belakang dan rumusan masalah yang telah diuraikan di atas, maka tujuan yang ingin dicapai pada penelitian ini adalah sebagai berikut :

1. Mengetahui model ARIMA yang sesuai untuk meramalkan jumlah kedatangan wisatawan asing yang datang ke Provinsi Bali.
2. Mengetahui arsitektur model RNN dan estimasi bobot optimal untuk meramalkan jumlah kedatangan wisatawan asing yang datang ke Provinsi Bali.
3. Mengetahui perbandingan hasil peramalan jumlah kedatangan wisatawan asing yang datang ke Provinsi Bali dengan menggunakan model ARIMA dan RNN.

1.4 Manfaat Penelitian

Berdasarkan pada rumusan masalah dan tujuan penelitian yang telah diuraikan di atas, diharapkan dari penelitian ini dapat memberikan manfaat yaitu sebagai tambahan informasi baik kepada pihak pemerintah provinsi Bali maupun kepada pihak pengusaha di bidang pariwisata mengenai jumlah wisatawan yang datang ke Bali, sehingga dapat digunakan sebagai pertimbangan untuk pengambilan keputusan di masa mendatang.

1.5 Batasan Masalah

Pada penelitian ini, peneliti ingin memberikan batasan masalah yaitu data yang digunakan dalam peramalan adalah data jumlah wisatawan asing yang datang ke provinsi Bali dari tahun 2006 sampai tahun 2013 dengan menggunakan metode ARIMA dan RNN.

BAB II TINJAUAN PUSTAKA

2.1 Analisis Deret Waktu (*Time Series*)

Time series adalah serangkaian observasi yang berurutan. Meskipun secara umum pengurutan observasinya berdasarkan waktu, khususnya dalam interval yang sama, pengurutan *time series* juga dapat dilakukan berdasarkan ruang. Beberapa tujuan dalam mempelajari *time series* antara lain dapat memahami dan menggambarkan suatu mekanisme pembentukan, meramalkan suatu nilai di masa depan dan mengoptimalkan control dari suatu sistem (Wei, 2006).

2.2 Uji Nonlinearitas Terasvirta

Sebelum melakukan pemodelan, Terasvirta *et al*(1991) menganjurkan terlebih dahulu agar dilakukan pengujian untuk melihat apakah terdapat nonlinearitas pada data *time series*. Pengujian dilakukan dengan tahapan sebagai berikut.

1. Regresikan Y_t pada $1, Y_{t-1}, \dots, Y_{t-p}$ dan hitung residual $\hat{u}_t$ dan *sum square residual* $S_u = \sum \hat{u}_t^2$
2. Regresikan $\hat{u}_t$ pada $1, Y_{t-1}, \dots, Y_{t-p}$ dan m regresor bantuan, hitung residual $\hat{v}_t$ dan *sum square residual* $S_v = \sum \hat{v}_t^2$ (m dan regresor bervariasi dari tes satu dan lainnya).
3. Hitung $F = \frac{(S_u - S_v)/m}{S_v/(T-p-1-m)}$

Dibawah hipotesis linearitas, F didekati dengan F didistribusikan dengan m dengan derajat bebas $T - p - 1 - m$, di mana p merupakan order lag pada model.

2.3 Model Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA merupakan gabungan dari model *Autoregressive* (AR) dan *Moving Average* (MA) di mana dilakukan *differencing* (orde d untuk data non musiman, orde D untuk data musiman) terhadap data *time series* tersebut (Wei, 2006).

2.3.1 Model ARIMA Non Musiman

Umumnya, model ARIMA non musiman dituliskan sebagai ARIMA (p,d,q) di mana p adalah orde AR, d adalah orde *differencing*, dan q adalah orde MA. Model matematisnya adalah sebagai berikut (Wei, 2006).

$$f_p(B)(1-B)^d Y_t = q_0 + q_q(B)a_t \quad (2.1)$$

dengan,

$\phi_p(B)$: polinomial model AR orde p ,

$$f_p(B) = (1 - f_1 B - f_2 B^2 - \dots - f_p B^p) \quad (2.2)$$

$\theta_q(B)$: polinomial model MA orde q ,

$$q_q(B) = (1 - q_1 B - q_2 B^2 - \dots - q_q B^q) \quad (2.3)$$

a_t : nilai residual pada saat t

2.3.2 Model ARIMA Musiman

Model ARIMA musiman dapat dituliskan sebagai ARIMA $(P,D,Q)^S$ di mana P adalah orde AR musiman, D adalah orde *differencing* musiman, Q adalah orde MA musiman, dan S adalah orde musiman. Berikut adalah model ARIMA musiman (Wei, 2006).

$$\Phi_P(B^S)(1-B^S)^D Y_t = \Theta_Q(B^S)a_t \quad (2.4)$$

dengan,

$\Phi_P(B^S)$: polinomial model AR musiman S order P ,

$$\Phi_P(B^S) = (1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS}) \quad (2.5)$$

$\Theta_Q(B^S)$: polinomial model MA musiman S orde Q ,

$$\Theta_Q(B^S) = (1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS}) \quad (2.6)$$

a_t : nilai residual pada saat t

Pembentukan model ARIMA dilakukan dengan menggunakan prosedur Box-Jenkins. Proses yang akan dilakukan antara lain identifikasi model, estimasi parameter, pengujian parameter, cek diagnosa, peramalan dan pemilihan model terbaik.

2.3.3 Model Multiplikatif ARIMA Musiman

Dengan menggabungkan ide dari model ARIMA musiman dan non musiman dapat dibentuk model yang memiliki autokorelasi untuk lag musiman dan lag non musiman (Cryer, 1986). Model multiplikatif ARIMA musiman dituliskan sebagai $ARIMA(p, d, q) \times (P, D, Q)_S$ di mana p adalah orde AR non musiman, d adalah orde *differencing* non musiman, q adalah orde MA non musiman, P adalah orde AR musiman, D adalah orde *differencing* musiman, Q adalah orde MA musiman, dan S adalah orde musiman. Berikut adalah model multiplikatif ARIMA musiman (Wei, 2006).

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

dengan,

$\phi_p(B)$: polinomial model AR orde p ,

$\theta_q(B)$: polinomial model MA orde q ,

$\Phi_P(B^S)$: polinomial model AR musiman S order P ,

$\Theta_Q(B^S)$: polinomial model MA musiman S orde Q ,

a_t : nilai residual pada saat t

2.4 Identifikasi Model

Identifikasi model yang perlu dilakukan dalam *time series* dimulai dengan identifikasi kestasioneran data, serta identifikasi *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data.

2.4.1 Stasioneritas

Untuk melihat kestasioneran data digunakan *time series plot*. Pertama, data yang tidak stasioner dalam varians diatasi dengan menggunakan transformasi Box-Cox yang dituliskan sebagai berikut.

$$Y_t^{(1)} = \frac{Y_t^1 - 1}{1} \quad (2.8)$$

Tabel berikut menyajikan beberapa bentuk transformasi Box-Cox berdasarkan nilai *rounded value* dari estimasi λ .

Tabel 2.1 Transformasi Box-Cox

Nilai Estimasi λ	Transformasi
-2.0	$1/Y_t^2$
-1.0	$1/Y_t$
-0.5	$1/\sqrt{Y_t}$
0	$\ln Y_t$
0.5	$\sqrt{Y_t}$
1.0	Y_t (tidak ada transformasi)
2.0	Y_t^2

Selanjutnya apabila terdeteksi data tidak stasioner dalam mean, maka diatasi dengan melakukan *differencing* yang akan menghasilkan *series* yang stasioner. Proses *differencing* untuk orde ke- d dapat ditulis sebagai berikut.

$$\Delta^d Y_t = (1 - B)^d Y_t \quad (2.9)$$

2.4.2 Autocorrelation Function (ACF)

ACF adalah fungsi yang menunjukkan hubungan linier pada data *time series* antara Y_t dengan Y_{t+k} . Dalam suatu proses stasioner $\{Y_t\}$, nilai dari $E(Y_t) = E(Y_{t+k}) = \mu$ dan nilai dari $\text{var}(Y_t) = \text{var}(Y_{t+k}) = \sigma^2$ menunjukkan bahwa nilai mean dan varians tersebut konstan. Persamaan dari kovarians antara $\{Y_t\}$ dengan $\{Y_{t+k}\}$ adalah sebagai berikut.

$$\hat{\gamma}_k = \text{cov}(Y_t, Y_{t+k}) = \sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y}) \quad (2.10)$$

Korelasi antara $\{Y_t\}$ dengan $\{Y_{t+k}\}$ adalah sebagai berikut.

$$\hat{\rho}_k = \frac{\text{cov}(Y_t, Y_{t+k})}{\sqrt{\text{var}(Y_t)} \sqrt{\text{var}(Y_{t+k})}} = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} \quad (2.11)$$

γ_k merupakan fungsi autokovarians dan $\bar{\rho}_k$ merupakan fungsi autokorelasi karena menjelaskan kovarians dan korelasi antara Y_t dan Y_{t+k} dari proses yang sama dan hanya terpisah oleh lag waktu ke k (Wei, 2006).

2.4.3 Partial Autocorrelation Function (PACF)

PACF adalah fungsi yang menunjukkan korelasi antara data Y_t dan Y_{t+k} setelah pengaruh dari variabel $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ dihilangkan. Nilai PACF sampel lag ke k dimulai dari $\hat{\phi}_1 = \bar{\rho}_1$, sedangkan selanjutnya untuk menghitung $\hat{\phi}_k$ menggunakan rumus sebagai berikut.

$$\hat{f}_{kk} = \text{corr}(Y_t, Y_{t+k} | Y_{t+1}, \dots, Y_{t+k-1}) \quad (2.12)$$

Selanjutnya didapatkan perhitungan PACF sampai lag ke k sebagai berikut.

$$\hat{f}_{k+1,k+1} = \frac{\hat{f}_{k+1} - \sum_{j=1}^k \hat{f}_{k+1,j} \hat{f}_{k+1-j}}{1 - \sum_{j=1}^k \hat{f}_{kj} \hat{f}_j} \quad (2.13)$$

$$\hat{\rho}_{kk} = \begin{cases} \hat{\rho}_1 & \text{jika } k=1 \\ \hat{\rho}_k - \sum_{j=1}^k \hat{\rho}_{k-1,j} \hat{\rho}_{k-j} & \text{jika } k=2,3,\dots \\ 1 - \sum_{j=1}^k \hat{\rho}_{k-1,j} \hat{\rho}_j & \end{cases} \quad (2.14)$$

2.5 Identifikasi Model ARIMA

Model ARIMA dapat diidentifikasi dengan melihat plot *time series*, plot ACF dan PACF. Plot ACF dan PACF digunakan untuk menentukan orde p dan q dari model ARIMA non musiman serta P dan Q dari model ARIMA musiman. Secara teoritis, bentuk-bentuk plot ACF dan PACF dari model ARIMA adalah seperti pada tabel berikut (Wei, 2006).

Tabel 2.2 Bentuk ACF dan PACF untuk Identifikasi Model ARIMA Non Musiman

Model	ACF	PACF
AR(p)	Turun cepat secara eksponensial menuju nol (dies down)	Terpotong setelah lag ke- p $\hat{\rho}_k \neq 0$ untuk $k = 1, 2, \dots, p$ $\hat{\rho}_k \approx 0$ untuk $k > p$
MA(q)	Terpotong setelah lag ke- q $\hat{\rho}_k \neq 0$ untuk $k = 1, 2, \dots, q$ $\hat{\rho}_k \approx 0$ untuk $k > q$	Turun cepat secara eksponensial menuju nol (dies down)
ARMA(p, q)	Turun cepat secara eksponensial menuju nol setelah lag ($q - p$)	Turun cepat secara eksponensial menuju nol setelah lag ($p - q$)

Tabel 2.3 Bentuk ACF dan PACF untuk Identifikasi Model ARIMA Musiman

Model	ACF	PACF
AR(P)	Turun cepat secara eksponensial menuju nol (dies down)	Terpotong setelah lag ke- P $\hat{\rho}_k \neq 0$ untuk $k = 1s, 2s, \dots, P$ $\hat{\rho}_k \approx 0$ untuk yang lain
MA(Q)	Terpotong setelah lag ke- Q $\hat{\rho}_k \neq 0$ untuk $k = 1s, 2s, \dots, Q$ $\hat{\rho}_k \approx 0$ untuk yang lain	Turun cepat secara eksponensial menuju nol (dies down)
ARMA(P, Q)	Turun cepat secara eksponensial pada level musiman	Turun cepat secara eksponensial pada level musiman

2.6 Penaksiran Parameter Model ARIMA

Metode penaksiran parameter model ARIMA digunakan metode *Least Square*. Dimisalkan model AR(1) yaitu $Y_t - \mu = \phi_1(Y_{t-1} - \mu) + a_t$. Model ini dapat dilihat sebagai suatu model regresi dengan variabel peramalan atau prediktor Y_{t-1} dan variabel respon Y_t . Metode *Least Square* merupakan suatu metode yang dilakukan dengan cara mencari nilai parameter yang

meminimumkan jumlah kuadrat residual. Sebagai contoh untuk model AR(1), dinyatakan dalam bentuk persamaan berikut.

$$S(f, m) = \sum_{t=2}^n a_t^2 = \sum_{t=2}^n [(Y_t - m) - f_1(Y_{t-1} - m)]^2 \quad (2.15)$$

Berdasarkan prinsip dari metode *Least Square*, penaksiran f_1 dan m dilakukan dengan meminimumkan $S(f_1, m)$. Hal ini dilakukan dengan menurunkan $S(f_1, m)$ terhadap m dan f_1 kemudian disamadengkan nol. Meminimumkan $S(f, m)$ terhadap m menghasilkan:

$$\frac{\partial S}{\partial m} = \sum_{t=2}^n 2[(Y_t - m) - f_1(Y_{t-1} - m)](-1 + f_1) = 0 \quad (2.16)$$

Dengan demikian akan diperoleh nilai taksiran parameter untuk m dari model AR(1) sebagai berikut.

$$\hat{m} = \frac{\sum_{t=2}^n Y_t - f_1 \sum_{t=2}^n Y_{t-1}}{(n-1)(1-f_1)} \quad (2.17)$$

Dengan cara yang sama, operasi turunan terhadap f_1 , yaitu

$$\frac{\partial S}{\partial \hat{f}_1} = \sum_{t=2}^n 2[(Y_t - \bar{Y}) - f_1(Y_{t-1} - \bar{Y})](Y_{t-1} - \bar{Y}) = 0 \quad (2.18)$$

Sehingga diperoleh nilai taksiran sebagai berikut.

$$\hat{f}_1 = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2} \quad (2.19)$$

Nilai-nilai persamaan tersebut merupakan taksiran parameter m dan f_1 (Cryer, 1986).

2.7 Pengujian Signifikansi Parameter

Uji signifikansi parameter dilakukan untuk mengetahui signifikansi parameter model ARIMA sehingga dapat diketahui variabel Y_{t-k} berpengaruh terhadap Y_t atau tidak. Pengujian hipotesis dilakukan dengan menggunakan uji t. Misalkan yang diuji adalah parameter MA yaitu θ , maka hipotesis yang digunakan adalah sebagai berikut.

$$H_0 : q_i = 0, \quad \forall i$$

$$H_1 : q_i \neq 0, \quad \exists i, i = 1, 2, \dots, q$$

$$\text{Statistika uji : } t_{hitung} = \frac{\hat{q}}{SE(\hat{q})}$$

Tolak H_0 jika $|t_{hitung}| > t_{\alpha, n-p}$, p merupakan banyaknya parameter, atau tolak H_0 jika $p - v < \alpha$, dengan α merupakan tingkat signifikansi kesalahan (Bowerman dan O'Connell, 1993).

2.8 Cek Diagnosa

Selanjutnya, dilakukan pengujian untuk mengetahui apakah residual telah memenuhi beberapa asumsi. Asumsi tersebut terdiri dari *white noise* dan kenormalan residual (Wei, 2006).

2.8.1 White Noise

Proses a_t (residual) dikatakan suatu proses *white noise* apabila tidak terdapat korelasi antar pengamatan, dengan nilai *mean* konstan $E(a_t) = \mu_a$, biasanya diasumsikan sebagai nol dan varians konstan, di mana $v(a_t) = \sigma_a^2$ dan $\gamma_k = c_1(a_t, a_{t+k})$, sehingga diperoleh

$$\gamma_k = \begin{cases} \sigma_a^2 & k = 0 \\ 0 & k \neq 0 \end{cases} \quad (2.20)$$

Dari definisi tersebut, dapat disimpulkan bahwa proses *white noise* adalah stasioner dengan fungsi autokovarian sebesar γ_k (Wei, 2006).

Untuk menguji apakah a_t sudah *white noise* digunakan uji Ljung-Box. Hipotesis dalam pengujian Ljung-Box adalah sebagai berikut.

$$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$$

$$H_1: \text{minimal ada satu } \rho_i \neq 0, \text{ untuk } i = 1, 2, \dots, k$$

Statistik uji yang digunakan adalah statistik uji Ljung-Box seperti pada persamaan berikut (Wei, 2006).

$$Q = n(n+2) \sum_{i=1}^k \frac{\hat{r}_i^2}{n-k} \quad (2.21)$$

n adalah banyak pengamatan dan $\hat{r}_k$ menunjukkan ACF residual pada lag ke k . H_0 ditolak jika nilai $Q > \chi^2_{(1-\alpha);k-m}$, dengan m adalah banyaknya parameter, atau nilai $p\text{-value} < \alpha$.

2.8.2 Distribusi Normal

Berikutnya dilakukan pengujian distribusi normal pada residual. Dalam hal ini digunakan uji *Kolmogorov-Smirnov* dengan hipotesis sebagai berikut.

$$H_0: F(x) = F_0(x) \text{ (Residual Berdistribusi Normal)}$$

$$H_1: F(x) \neq F_0(x) \text{ (Residual tidak Berdistribusi Normal)}$$

Statistik uji:

$$D = \sup |S(x) - F_0(x)|$$

$S(x)$ = fungsi peluang kumulatif dari data sampel

$F_0(x)$ = fungsi peluang kumulatif dari distribusi normal

$\sup$ = Nilai supremum untuk semua x dari $|S(x) - F_0(x)|$

H_0 ditolak jika $D > D_{(1-\alpha);n}$; dengan n adalah ukuran sampel.

2.9 Artificial Neural Network

Artificial Neural Network (ANN) adalah sistem pemrosesan informasi yang memiliki kinerja tertentu yang mirip dengan jaringan syaraf biologis. ANN telah dikembangkan sebagai generalisasi model matematis dari syaraf biologis, berdasarkan asumsi berikut (Fausett, 1994).

1. Proses informasi terjadi pada banyak elemen sederhana yang disebut neuron.
2. Sinyal diteruskan antar neuron melalui *connection links*.
3. Tiap *connection link* memiliki bobot yang bersangkutan, di mana pada umumnya menggandakan sinyal yang dikirim.
4. Tiap neuron memiliki fungsi aktivasi untuk *net input* yang bersangkutan untuk menentukan sinyal *outputnya*.


ANN memiliki beberapa komponen seperti neuron, *layer*, fungsi aktivasi, dan bobot. Pemodelan ANN dapat dianggap sebagai bentuk jaringan dari ANN itu sendiri, termasuk jumlah neuron dalam *layer* input, *hidden layer*, *layer* output, dan juga fungsi transfernya (Endharta dan Suhartono, 2009).

2.9.1 Arsitektur ANN


Untuk memudahkan dalam menganalisis, neuron-neuron pada ANN dikelompokkan ke dalam beberapa lapisan atau *layer*. Neuron yang berada pada *layer* yang sama memiliki perilaku yang sama juga. Faktor penting yang digunakan untuk menentukan perilaku dari sebuah neuron adalah fungsi aktivasi dan pola dari bobotnya (*update* bobot). Penggabungan dari beberapa neuron menjadi *layer* dan pola koneksi dalam dan antar *layer* disebut arsitektur ANN.

Pada arsitektur ANN dimungkinkan tidak adanya *hidden layer*, yang biasanya disebut dengan arsitektur *single layer perceptron*. ANN dengan *single layer perceptron* tidak memiliki *layer* tambahan di antara unit input (unit yang menerima sinyal dari luar) dan unit output (unit hasil dari pengolahan jaringan),

sehingga hanya terdapat satu lapisan bobot. Sedangkan ANN dengan *multi layer perceptron* memiliki *hidden layer*, di mana terdapat satu atau lebih layer di antara unit input dan unit output. ANN *multi layer* dapat menyelesaikan masalah yang lebih rumit jika dibandingkan dengan ANN *single layer*, akan tetapi dalam proses trainingnya mungkin lebih sulit (Fausett, 1994).



Gambar 2.1 Arsitektur Single Layer Perceptron



Gambar 2.2 Arsitektur Multilayer Perceptron

Arsitektur ANN yang banyak digunakan adalah *feedforward neural network* (FFNN) dan *recurrent neural*

network (RNN). Pada FFNN, informasi mengalir dari unit input menuju unit output, tetapi tidak bisa sebaliknya. Sedangkan pada RNN terdapat hubungan antar unit yang membentuk suatu pengulangan, sehingga memungkinkan terjadinya pergerakan informasi dari unit output untuk kembali ke unit input (Haykin, 1994). Dalam pemodelan statistika untuk peramalan *time series*, model FFNN dapat dikatakan sebagai model *autoregressive* (AR) non linier. Model ini memiliki kelemahan yaitu hanya dapat merepresentasikan efek AR dari data *time series*. Oleh karena itu digunakan model RNN, yang juga disebut sebagai model *Autoregressive Moving Average-Neural Network* (ARMA-NN), karena inputnya bukan hanya lag dari variabel respon, tetapi juga lag dari *error*. RNN merupakan model yang non linier (Endharta, 2009).

2.9.2 Feed Forward Neural Network

Pelatihan jaringan pada model *Feed Forward Neural Network* (FFNN) menggunakan algoritma backpropagation yang meliputi tiga tahap yaitu umpan maju (*feedforward*) dari pola input, penghitungan dan propagasi balik dari error dan penyesuaian bobot. Pada tahap umpan maju setiap unit input menerima sinyal input (x_i) dan menyebarkannya ke unit tersembunyi $z_1, \dots, z_p$. Setiap unit tersembunyi menghitung aktivasinya dan jumlah terboboti dari input-inputnya dalam bentuk:

$$z_{ij} = \sum_j w_j x_i + w_b \quad (2.22)$$

dimana x_i adalah aktivasi dari unit input ke- i yang mengirimkan sinyal ke unit hidden ke j , w_j adalah bobot dari sinyal yang terkirim dan $j = 1, 2, \dots, q$ adalah jumlah *hidden unit*. Hasil penjumlahan ditransformasi dengan fungsi aktivasi nonlinear:

$$z_j = f(z_{ij}) \quad (2.23)$$

Setelah semua unit tersembunyi menghitung aktivasinya kemudian mengirimkan sinyal (z_j) ke unit output. Kemudian unit output menghitung aktivasinya dalam bentuk:

$$g(w, z) = \sum_j w_j z_j + w_b \quad (2.24)$$

Fungsi pada (2.23) merupakan nilai output dari jaringan yaitu:

$$y = \sum_j w_j f(a_j) + w_b \quad (2.25)$$

dimana w_{b0} adalah bobot dari bias ke unit output.

Arsitektur model FFNN dengan unit input lag 1 sampai p dan unit konstan, satu *hidden layer* dengan 3 neuron dan 1 unit output diilustrasikan pada gambar berikut.



Gambar 2.3 Arsitektur FFNN

Model FFNN dengan satu *hidden layer* dan input ditulis dalam bentuk:


$$x_t = \psi_c \{w_c + \sum_n w_n \psi_n(w_c + \sum_i w_{in} x_{t-j_i})\} \quad (2.26)$$

dimana w_{cn} adalah bobot antara unit konstan dan neuron dan w_{co} adalah bobot antara unit konstan dan output. w_{in} dan w_{no} masing-masing menyatakan bobot koneksi input dengan neuron dan antara neuron dengan output. Kedua fungsi ψ_n dan ψ_c masing-masing adalah fungsi aktivasi yang digunakan pada neuron dan output. Notasi untuk model FFNN adalah $NN(j_1, \dots, j_k, n)$ yang menyatakan NN dengan input lag $j_1, \dots, j_k$ dan n neuron.

2.9.3 Elman Recurrent Neural Network

Elman Recurrent Neural Network (ERNN) merupakan suatu ANN dengan arsitektur di mana terdapat suatu kelompok unit yang menerima sinyal *feedback* dari data waktu lampau. Kelompok unit ini disebut *context units*. Bobot dari koneksi *feedback* menuju unit *context* adalah tetap, dan pemrosesan informasi tetap berurutan berdasarkan waktu, sehingga dalam

training tidak lebih sulit dari jaringan *backpropagation* pada umumnya (Fausett, 1994). Dalam penentuan unit input dan unit output ERNN untuk peramalan, dapat dilihat pada gambar berikut.



Gambar 2.4 Arsitektur ERNN untuk Peramalan

Berdasarkan Gambar 2.4 diketahui bahwa untuk input unitnya digunakan lag-lag yang signifikan dari hasil pemodelan ARIMA. Sedangkan untuk unit *context* digunakan lag dari *error*.

Estimasi bobot dan bias pada model ERNN menggunakan algoritma *backpropagation*. Untuk RNN yang umum dengan 1 *hidden layer*, unit input sebanyak q dan unit di *hidden layer* sebanyak p , persamaannya adalah sebagai berikut.

$$Y = f^u \left[\beta_u + \sum_{j=1}^p \left(\beta_j f^h(y_{ju} + \sum_{l=1}^q \gamma_j x_l) \right) \right] \quad (2.27)$$

Di mana β_j adalah bobot dari unit ke- j pada *hidden layer*, γ_j adalah bobot dari input ke- l yang pergi menuju unit ke- j pada *hidden layer*, $f^h(x)$ adalah fungsi aktivasi pada *hidden layer*, dan $f^u(x)$ adalah fungsi aktivasi pada *layer output*. Chong dan Zak (1996) menjelaskan bahwa bobot dan biasnya dapat diestimasi dengan meminimalkan nilai E pada persamaan berikut.

$$E = \frac{1}{2} \sum_{k=1}^n [Y_{(k)} - \hat{Y}_k]^2 \quad (2.28)$$

Minimalisasi dari persamaan tersebut dilakukan dengan menggunakan metode *gradient descent* dengan momentum.

Metode *gradient descend* dengan momentum m , $0 < m < 1$, diformulasikan dengan:

$$w^{(l+1)} = w^{(l)} - \left(m \cdot d^{(l)} + (1 - m)\eta \frac{\partial}{\partial} \right) \quad (2.29)$$

di mana d adalah perubahan bobot atau bias, η adalah *learning rate* yang ditentukan, $0 < \eta < 1$. Untuk menyelesaikan persamaan tersebut, dilakukan turunan parsial dari E untuk setiap bobot dan bias w dengan aturan rantai (Endharta dan Suhartono, 2009). Hasil akhirnya didapatkan update bobot dan bias pada *layer* output sebagai berikut.

$$\beta_j^{(s+1)} = \beta_j^{(s)} - \left(m \cdot d^{(s)} + (m - 1)\eta \sum_{k=1}^n \delta_{(k)}^U V_{j(k)} \right) \quad (2.30)$$

$$\beta_U^{(s+1)} = \beta_U^{(s)} - \left(m \cdot d^{(s)} + (m - 1)\eta \sum_{k=1}^n \delta_{(k)}^U \right) \quad (2.31)$$

Update bobot dan bias pada *hidden layer* adalah sebagai berikut.

$$\gamma_j^{(s+1)} = \gamma_j^{(s)} - \left(m \cdot d^{(s)} + (m - 1)\eta \sum_{k=1}^n \delta_{(k)}^H X_{i(k)} \right) \quad (2.32)$$

$$\gamma_{jU}^{(s+1)} = \gamma_{jU}^{(s)} - \left(m \cdot d^{(s)} + (m - 1)\eta \sum_{k=1}^n \delta_{(k)}^H \right) \quad (2.33)$$

di mana d adalah perubahan bobot atau bias yang bersangkutan, m adalah momentum dan η adalah *learning rate*.

2.10 Kriteria Keباikan Model

Terdapat dua pendekatan dalam menentukan kebaikan model. Yang pertama adalah pendekatan *in-sample* di mana penilaiannya berdasarkan nilai residual pada model dan *out-sample* di mana penilaiannya berdasarkan *error* dari hasil ramalan. Pendekatan *out sample* dilakukan dengan menggunakan sebagian data untuk melakukan pemodelan dan sebagian sisanya digunakan untuk evaluasi terhadap hasil peramalan model tersebut (Wei, 2006). Untuk penilaian *in-sample* digunakan kriteria *Akaike's Information Criterion* (AIC). Sedangkan untuk penilaian *out-sample* digunakan *Mean Absolute Percentage Error* (MAPE), *Root of Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE).

Nilai AIC dirumuskan dengan

$$A = n \ln(\hat{\sigma}_e^2) + 2k \quad (2.34)$$

Dengan n adalah banyaknya pengamatan, k adalah banyaknya parameter dalam model, $\hat{\sigma}_a^2$ adalah σ_a^2 nilai yang diestimasi dengan MLE. Perhitungan nilai $\hat{\sigma}_a^2$ dihitung berdasarkan persamaan

$$\hat{\sigma}_a^2 = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (2.35)$$

Nilai MAPE dapat dihitung berdasarkan rumus berikut.

$$M = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\% \quad (2.36)$$

Model terbaik adalah model dengan nilai MAPE yang paling kecil. Nilai RMSE dihitung seperti persamaan berikut.

$$R = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (2.37)$$

Model terbaik adalah model dengan nilai RMSE yang paling kecil. Nilai MAE dihitung dengan rumus:

$$M = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (2.38)$$

Model terbaik adalah model dengan nilai MAE yang paling kecil.

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang bersumber dari Badan Pusat Statistik Provinsi Bali. Variabel yang akan diteliti adalah jumlah wisatawan mancanegara yang datang ke provinsi Bali pada tiap-tiap bulan dari bulan Januari tahun 2006 sampai bulan Desember tahun 2013.


3.2 Metode Analisis

Pada penelitian ini digunakan 2 metode peramalan yaitu dengan menggunakan model ARIMA dan dengan menggunakan model Elman-RNN, dan akurasi hasil peramalan dari masing-masing metode akan dibandingkan. Adapun tahapan analisisnya adalah sebagai berikut.


- a. Membagi data menjadi 2 bagian, yaitu data *in-sample* dan *outsample*. Data *in-sample* yang digunakan sebanyak 84 data, sedangkan *out-sample* sebanyak 12 data. Dalam pemodelan akan digunakan data *in-sample*.
- b. Memeriksa stasioneritas data. Jika data tidak stasioner dalam varians, maka untuk menstasionerkan dilakukan transformasi Box-Cox. Jika data tidak stasioner dalam *mean*, maka untuk menstasionerkan dilakukan *differencing*.
- c. Setelah data sudah stasioner dalam mean dan varians, langkah selanjutnya adalah membuat *time series plot*, plot ACF, dan PACF.
- d. Mengidentifikasi dugaan model sementara berdasarkan plot ACF dan PACF.
- e. Melakukan estimasi parameter dari model ARIMA kemudian dilakukan uji signifikansi parameter.
- f. Penggunaan model ARIMA untuk meramalkan data *out-sample* dari jumlah kedatangan wisatawan mancanegara di masa yang akan datang.

- g. Menghitung nilai *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE) dari hasil peramalan *out-sample* model ARIMA.
- h. Melakukan training *Elmann Recurrent Neural Network* (RNN) dengan input lag-lag signifikan dari model ARIMA.
- i. Penggunaan model hasil dari training RNN untuk meramalkan data *out-sample* dari jumlah kedatangan wisatawan mancanegara di masa yang akan datang.
- j. Menghitung nilai MAPE dan RMSE dari hasil peramalan *out-sample* dengan menggunakan jaringan dari hasil training RNN.
- k. Menentukan metode yang lebih baik dengan membandingkan hasil perhitungan nilai MAPE dan RMSE dari masing-masing metode.
- l. Meramalkan jumlah kedatangan wisatawan asing yang datang ke Bali dengan menggunakan metode yang terpilih paling baik, untuk bulan Januari 2014 sampai Desember 2014.

3.3 Diagram Alir



Gambar 3.1 Diagram Alir Pemodelan ARIMA



Gambar 3.2 Diagram Alir Metode ANN

BAB IV

ANALISIS DAN PEMBAHASAN

Bab ini akan menjelaskan analisis yang dilakukan, yaitu metode ARIMA dan metode Elman-RNN dalam peramalan jumlah wisatawan asing yang datang ke provinsi Bali. Akan tetapi sebelum peramalan dilakukan, pertama-tama dilakukan deskripsi secara statistik terhadap data jumlah kedatangan wisatawan asing, dengan tujuan mengetahui perilaku wisatawan yang datang ke Bali.


4.1 Analisis Deskriptif Jumlah Wisatawan Asing yang Datang ke Provinsi Bali

Objek penelitian yang digunakan adalah jumlah wisatawan asing yang datang ke provinsi Bali pada tahun 2006 sampai tahun 2013 (data pada Lampiran 1), dengan rata-rata sebanyak 2379007 orang per tahun. Data kedatangan wisatawan asing merupakan data yang terhitung per bulan setiap tahunnya. Untuk mengetahui perilaku wisatawan asing yang datang ke Bali, dapat dilihat dari data jumlah kedatangan per bulan dan per tahun.

Dapat dilihat pada Tabel 4.1 bahwa jumlah kedatangan wisatawan asing paling banyak adalah pada bulan Juli yaitu sebanyak 227646 wisatawan, dan jumlah kedatangan wisatawan asing paling sedikit pada bulan Februari yaitu sebanyak 171003 wisatawan. Hal ini dikarenakan karena pada bulan Juli kebanyakan libur sekolah sudah dimulai, sehingga banyak keluarga dengan anak memilih untuk liburan pada bulan ini. Sedangkan untuk bulan Februari kedatangan wisatawan asing rendah dikarenakan belum dimulainya liburan serta musim hujan yang biasanya deras melanda sepanjang bulan sehingga dihindari wisatawan. Jumlah kedatangan wisatawan asing ke Bali terlihat rendah pada bulan Januari sampai Mei, sedangkan tinggi pada bulan Juni sampai Desember. Pola rata-rata kedatangan wisatawan asing per bulan dapat dilihat pada gambar 4.1 berikut.

Tabel 4.1 Statistik Deskriptif Kedatangan Wisatawan Asing Per Bulan

Bulan	Pengamatan	Rata-Rata	St. Deviasi
Januari	8	173351	59342
Februari	8	171003	57033
Maret	8	177036	56087
April	8	181324	49893
Mei	8	183797	48573
Juni	8	203467	56076
Juli	8	227646	62283
Agustus	8	222263	59710
September	8	217690	61355
Oktober	8	208604	54846
November	8	198201	60317
Desember	8	214626	61061
Keseluruhan	96	198251	57373



Gambar 4.1 Rata – rata kedatangan wisatawan asing per bulan

4.2 Uji Nonlinearitas Data Jumlah Wisatawan Asing yang Datang ke Provinsi Bali

Untuk menguji nonlinieritas data *time series* jumlah wisatawan asing yang datang ke provinsi Bali digunakan uji

Terasvirta. Pengujian dilakukan dengan menggunakan data *in-sample* dan nilai lag $p = 1$. Hasilnya adalah sebagai berikut.


Tabel 4.2 Uji Nonlinearitas Terasvirta

F_{hitung}	2.402
Derajat Bebas	2
P_{value}	0.092

Dari Tabel 4.2 dapat dilihat bahwa nilai P_{value} pada uji linearitas *time series* data lebih besar dari 0.05 sehingga dapat disimpulkan bahwa terdapat linearitas pada model dengan lag 1 dari data jumlah wisatawan asing yang datang ke provinsi Bali.

4.3 Metode ARIMA


Dalam penentuan model ARIMA, data yang akan digunakan adalah data *in-sample*. Pola kedatangan wisatawan asing dari bulan Januari tahun 2006 sampai bulan Desember tahun 2013 dapat dilihat pada Gambar 4.2 di bawah ini.



Gambar 4.2 Plot *Time Series* dari Data Kedatangan Wisatawan Asing Per Bulan


Pertama-tama dilakukan pengecekan apakah data sudah stasioner atau belum. Untuk mengetahui stasioneritas data dalam

varians dilakukan uji Box-Cox, sedangkan untuk mengetahui stasioneritas dalam *mean* dilihat dari plot ACF data.




Gambar 4.3 Plot Box-Cox dari Data Kedatangan Wisatawan Asing Per Bulan

Berdasarkan plot Box-Cox data *in-sample* pada Gambar 4.3 terlihat bahwa nilai λ sebesar 1, yang menunjukkan bahwa data sudah stasioner dalam varians. Plot ACF data (lihat Gambar 4.4) menunjukkan bahwa nilai ACF data turun sangat lambat (*dies down very slowly*) sehingga dapat disimpulkan bahwa data belum stasioner dalam *mean*. Oleh karena itu, akan dilakukan *differencing 1 lag* pada data.




Gambar 4.4 Plot ACF dari Data Kedatangan Wisatawan Asing Per Bulan

Berdasarkan Gambar 4.6 terlihat bahwa pola data *differencing* 1 sudah stasioner. Gambar 4.6 menunjukkan bahwa sudah tidak ada lag yang nilai ACF-nya turun lambat, sehingga dapat disimpulkan bahwa data kedatangan wisatawan asing ke Bali sudah stasioner setelah dilakukan *differencing* 1 lag. Akan tetapi karena pada plot *time series* data terlihat pola musiman, maka akan dilakukan *differencing* 12 lag.




Gambar 4.5 Plot Time Series dari Data Differencing 1 Lag




Gambar 4.6 Plot ACF dari Data Differencing 1 Lag

Berdasarkan Gambar 4.7 terlihat bahwa pola data *differencing* 1 dan 12 lag stasioner. Gambar 4.8 menunjukkan bahwa sudah tidak ada lag yang nilai ACF-nya turun lambat, sehingga dapat disimpulkan bahwa data kedatangan wisatawan asing ke Bali sudah stasioner setelah dilakukan *differencing* 1 lag dan *differencing* musiman tahunan (12 lag).




Gambar 4.7 Plot Time Series dari Data *Differencing* 1 dan 12 Lag



Gambar 4.8 Plot ACF dari Data *Differencing* 1 dan 12 Lag

Plot ACF data (Gambar 4.8) menunjukkan bahwa lag 1 dan 11, serta lag 12 (musiman tahunan) keluar batas signifikansi. Pada plot PACF data (Gambar 4.9), dapat dilihat bahwa lag 1, 2, 10, dan 13 keluar batas signifikansi.



Gambar 4.9 Plot PACF dari Data *Differencing* 1 dan 12 Lag

Berdasarkan lag-lag yang keluar batas signifikansi plot ACF dan PACF data *differencing* 1 dan 12, model ARIMA dugaannya adalah ARIMA $([1,2,10,13],1,[1,11])(0,1,1)_{12}$. Selanjutnya parameter model akan diestimasi dan diuji untuk mengetahui apakah model sudah signifikan berbeda dengan nol. Hasilnya dapat dilihat pada Tabel 4.3.

Tabel 4.3 Uji Signifikansi Model ARIMA $([1,2,10,13],1,[1,11])(0,1,1)_{12}$

Parameter	Koefisien	Standar Error	t_{hitung}	P _{value}
MA1,1	0.88275	0.0534	16.53	<.0001
MA1,2	-0.22286	0.05412	-4.12	0.0001
MA2,1	0.62333	0.11879	5.25	<.0001
AR1,1	0.26794	0.13231	2.03	0.047
AR1,2	0.07441	0.13372	0.56	0.5798
AR1,3	-0.0211	0.13835	-0.15	0.8792
AR1,4	-0.06234	0.14797	-0.42	0.675

Dapat dilihat bahwa terdapat parameter yang tidak signifikan pada model ARIMA $([1,2,10,13],1,[1,11])(0,1,1)_{12}$. Parameter-parameter yang tidak signifikan ini akan dikeluarkan dari model sampai semua parameternya signifikan. Model akhir yang didapatkan adalah ARIMA $(1,1,[1,11])(0,1,1)_{12}$. Uji signifikansi parameternya dapat dilihat pada Tabel 4.4.

Tabel 4.4 Uji Signifikansi Model ARIMA $(1,1,[1,11])(0,1,1)_{12}$

Parameter	Koefisien	Standar Error	t_{hitung}	P _{value}
MA1,1	0.90489	0.03593	25.18	<.0001
MA1,2	-0.20788	0.03581	-5.81	<.0001
MA2,1	0.64303	0.11004	5.84	<.0001
AR1,1	0.27116	0.12681	2.14	0.0361

Model ARIMA $(1,1,[1,11])(0,1,1)_{12}$ secara matematis ditulis sebagai berikut.

$$\begin{aligned}
 Y_t = & 1,271Y_{t-1} - 0,271Y_{t-2} + Y_{t-1} - 1,271Y_{t-1} \\
 & + 0,271Y_{t-1} + u_t + 0,905u_{t-1} \\
 & + 0,208u_{t-1} - 0,643u_{t-1} + 0,582u_{t-1} \\
 & - 0,134u_{t-2}
 \end{aligned}$$

Setelah signifikansi parameter diuji, selanjutnya dilakukan cek diagnosa. Residual model diuji apakah sudah memenuhi asumsi *white noise* dan berdistribusi normal.

Tabel 4.5 Uji *White Noise* Residual Model ARIMA $(1,1,[1,11])(0,1,1)_{12}$

Hingga Lag	χ^2_n	Derajat Bebas	P _{value}
6	2.66	2	0.2639
12	6.49	8	0.5921
18	9.97	14	0.7647
24	12.71	20	0.8896

Dari Tabel 4.5 dapat dilihat bahwa nilai P_{value} pada uji *white noise* residual lebih besar dari 0,05 sehingga dapat disimpulkan bahwa residual data sudah memenuhi asumsi *white noise*.

Tabel 4.6 Uji Kolmogorov-SmirnovResidual Model ARIMA (1,1,[1,11])(0,1,1)₁₂

D _{hitung}	0.061764
P_{value}	>0.1500

Dari Tabel 4.6 dapat dilihat bahwa nilai P_{value} pada uji normalitas data lebih besar dari 0.05 sehingga dapat disimpulkan bahwa residual data sudah memenuhi asumsi berdistribusi normal.

4.4 Metode Elman-Recurrent Neural Network

Dalam pemodelan dengan metode *neural network*, diperlukan penentuan input, fungsi aktivasi, dan banyaknya unit dalam *hidden layer*. Input yang digunakan dalam model NN adalah variabel prediktor pada model ARIMA dugaan dengan parameter yang sudah signifikan, yaitu lag 1, 2, 12, 13, dan 14. Setelah data diinput, data dibagi menjadi 2 bagian, yaitu data *in-sample* dan data *out-sample*. Lalu, dibentuk sebuah jaringan Elman-reccurent neural network (ERNN) yang menggunakan fungsi transfer *tangent sigmoid* pada *hidden layer*, dan fungsi transfer linier pada *output layer*. Update bobot dan bias pada ERNN dilakukan dengan metode *gradient descend momentum* dan *adaptive learning rate*. Proses *training* dilakukan dengan menggunakan data *in-sample*, dengan jumlah maksimum *epoch* sebanyak 1000, *learning rate* sebesar 0.1 dan momentum sebesar 0.8. Jumlah *hidden layer* yang digunakan pada ERNN bervariasi dari ERNN dengan 1 *hidden layer* sampai ERNN dengan 10 *hidden layer*. Hal ini bertujuan untuk mengetahui jumlah *hidden layer* yang memberikan hasil training data dengan kriteria *out-sample* yang terbaik.

Berdasarkan Tabel 4.7 dapat dilihat bahwa jaringan *recurrent* yang terbaik dari data *in-sample* adalah jaringan ERNN dengan unit pada *hidden layer* sebanyak 4. Hal ini ditunjukkan oleh nilai MAPE dan MAE yang dihasilkan dari data *out-sample* bernilai paling kecil, yaitu sebesar 5.417 dan 14541. Huruf *k* pada Tabel 4.7 menunjukkan banyaknya bobot pada jaringan. Oleh karena itu, jaringan NN yang akan dibuat adalah jaringan (5,4,1) yaitu jaringan dengan 5 input, 4 unit pada *hidden layer* dengan fungsi transfer *tangent sigmoid*, dan 1 unit pada *output layer* dengan fungsi linier.

Tabel 4.7 Kriteria Keباikan Jaringan RNN

Hidden Unit	k	Kriteria In-Sample			Kriteria Out-Sample		
		AIC	SBC	RMSE	MAPE	RMSE	MAE
1	8	36.098	19.098	14116	6.942	22631	17533
2	15	34.912	24.110	12516	5.809	22279	17692
3	22	34.697	27.087	13647	6.362	22207	21965
4	29	34.404	28.955	12795	5.417	21884	14541
5	36	35.399	31.587	22122	6.796	22749	16457
6	43	34.129	31.636	12127	5.440	21027	19169
7	50	34.357	32.971	13944	6.497	22593	15443
8	57	34.772	34.338	17459	6.119	21076	20200
9	64	35.210	35.613	21968	7.560	23647	16967
10	71	35.634	36.783	27399	7.804	22790	16712

Berikut adalah nilai bias dan bobot input, dan bobot *hidden layer* untuk jaringan (5,4,1).

Tabel 4.8 Bias Input Jaringan (5,4,1)

Bias Input			
Unit 1	Unit 2	Unit 3	Unit 4
0.265	-0.781	-0.237	-0.191

Tabel 4.9 Bobot Input Jaringan (5,4,1)


Bobot Input				
Lag	Unit 1	Unit 2	Unit 3	Unit 4
1	0.596	0.189	0.599	-0.690
2	0.832	-0.812	-0.777	0.365
12	1.002	-0.673	-0.357	0.739
13	-0.348	-0.573	-0.408	-0.620
14	0.501	0.545	0.581	0.118

Tabel 4.10 Bobot *Hidden Layer* Jaringan (5,4,1)


Bobot <i>Hidden Layer</i>			
Unit 1	Unit 2	Unit 3	Unit 4
-1.516	-0.595	0.317	-1.604

4.5 Perbandingan Model ARIMA dan Jaringan Elman-RNN

Model ARIMA yang akan dibandingkan adalah model ARIMA (1,1,[1,11])(0,1,1)₁₂, dan jaringan Elman-RNN (5,4,1). Plot hasil dari pengolahan data *out-sample* digunakan untuk menentukan model yang terbaik. Semakin ramalan *out-sample* suatu metode mendekati data *out-sample* actual, maka semakin baik metode tersebut. Hasilnya dapat dilihat pada Gambar 4.10. Selain itu juga dapat dilihat residual model pada Gambar 4.11.



Gambar 4.10 Perbandingan Out-Sample RNN(5,4,1), ARIMA(1,1,[1,11])(0,1,1)₁₂, dan Data Aktual



Gambar 4.11 Perbandingan Residual RNN(5,4,1), ARIMA(1,1,[1,11])(0,1,1)₁₂

Pada Tabel 4.8 dapat dilihat kriteria kebaikan *out-sample* dari kedua metode. Nilai MAPE serta RMSE dari jaringan RNN(5,4,1) lebih kecil dari model ARIMA(1,1,[1,11])(0,1,1)₁₂ yaitu MAPE sebesar 5.41% dan RMSE sebesar 21884. Dapat disimpulkan bahwa jaringan Elman-RNN merupakan metode yang paling baik dalam meramalkan jumlah kedatangan wisatawan asing ke Bali.

Tabel 4.11 Kriteria Kebaikan *Out-Sample*

Metode	Kriteria Out-Sample		
	MAPE	RMSE	MAE
ARIMA(1,1,[1,11])(0,1,1) ₁₂	6.965	27181	20198
RNN(5,4,1)	5.417	21884	14541

4.6 Peramalan Jumlah Kedatangan Wisatawan Asing yang Datang ke Bali

Metode yang cukup baik untuk meramalkan jumlah kedatangan wisatawan asing ke Bali adalah. Selanjutnya akan dilakukan peramalan dengan metode tersebut untuk meramalkan jumlah kedatangan wisatawan asing ke Bali untuk jangka waktu dari bulan Januari 2014 sampai Desember 2014. Hasilnya dapat dilihat pada Tabel 4.9.

Tabel 4.12 Hasil Peramalan Kedatangan Wisatawan Asing Pada Tahun 2014

Bulan	Jumlah Wisatawan Asing
Januari	294739
Februari	316699
Maret	293031
April	225984
Mei	272303
Juni	324374
Juli	329424
Agustus	328738
September	266658
Oktober	228593
November	224719
Desember	324764



Halaman ini sengaja dikosongkan

BAB V

KESIMPULAN DAN SARAN


5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan maka dapat disimpulkan sebagai berikut.

1. Model ARIMA yang digunakan untuk meramalkan jumlah kedatangan wisatawan asing ke Bali adalah model $ARIMA(1,1,[1,11])(0,1,1)_{12}$, dengan nilai MAPE sebesar 6.965% dan RMSE *out-sample* sebesar 27181.
2. Jaringan terbaik yang dihasilkan metode RNN adalah jaringan RNN(5,4,1) dengan input adalah lag 1, 2, 12, 13, dan 14. Fungsi transfer yang digunakan adalah fungsi *tangent sigmoid* pada *hidden layer* dan fungsi linier pada *output layer*. Jaringan ini menghasilkan nilai MAPE sebesar 5.417%, RMSE *out-sample* sebesar 21884, dan MAE sebesar 14541.
3. Metode terbaik berdasarkan kedua metode untuk meramalkan jumlah kedatangan wisatawan asing ke Bali adalah metode Elman-RNN karena nilai MAPE jaringan RNN(5,4,1) lebih kecil dari nilai MAPE model $ARIMA(1,1,[1,11])(0,1,1)_{12}$.

5.2 Saran

Berdasarkan penelitian yang dilakukan hanya terdapat satu input yang digunakan dalam Elman-RNN, yaitu input dari hasil pemodelan ARIMA. Untuk penelitian selanjutnya disarankan agar menambahkan input lainnya agar dapat dijadikan bahan pembandingan terhadap jaringan RNN dengan input hasil pemodelan ARIMA.



LAMPIRAN

Lampiran 1. Data Kedatangan Wisatawan Asing ke Provinsi Bali

Bulan	2006	2007	2008	2009
Jan	80002	109875	147799	174541
Feb	73075	118483	161776	147704
Mar	84262	119458	160708	168205
Apr	104044	125393	154911	188776
Mei	101951	129039	167463	190803
Jun	109825	145500	178404	200566
Jul	122323	164972	190854	235198
Ags	118441	167031	195549	232255
Sep	118551	152804	189346	218443
Okt	112876	146385	189234	221282
Nov	114081	142124	173077	184803
Des	123106	147467	175963	222546
Angka Tahunan	1262537	1668531	2085084	2385122

Bulan	2010	2011	2012	2013
Jan	179273	209093	253286	232935
Feb	191926	207195	225993	241868
Mar	192579	207907	230957	252210
Apr	184907	224704	225488	242369
Mei	203388	209058	220700	247972
Jun	228045	245652	244080	275667
Jul	254907	283524	271512	297878
Ags	243154	258377	254079	309219
Sep	240947	258440	257363	305629
Okt	229904	247565	255021	266562
Nov	199861	221603	242781	307276
Des	227251	253591	268072	299013
Angka Tahunan	2576142	2826709	2949332	3278598

Lampiran 2. Uji Terasvirta

```
x<-read.csv(file="C:/Users/I Putu Prasetya W/Documents/R
TA/data.csv",head=TRUE)
> x<-as.ts(x)
> terasvirta.test(x,1,c("F"))
```

Terasvirta Neural Network Test

data: x

F = 2.4032, df1 = 2, df2 = 81, p-value = 0.09685

Lampiran 3. Program Recurrent Neural Network

```
all=length(data)
ins=all-12
pred=size(data,2)
P=data(1:ins,2:pred);
T=data(1:ins,1);
[pn,ps]=mapminmax(P);
[tn,ts]=mapminmax(T);
for i=1:10;
net=newelm(pn,tn,[i],{'tansig'},'traingdx');
bobotawal_input=net.IW{1,1};
bobotawal_bias_input=net.b{1,1};
bobotawal_lapisan1=net.LW{2,1};
bobotawal_bias_lapisan1=net.b{2,1};
net.trainparam.epochs=1000;
net.trainparam.goal=1e-3;
net.trainparam.lr=0.1;
net.trainparam.show=100;
net.trainparam.mc=0.8;
net=train(net,pn,tn);
bobotakhir_input=net.IW{1,1};
bobotakhir_bias_input=net.b{1,1};
bobotakhir_lapisan1=net.LW{2,1};
bobotakhir_bias_lapisan1=net.b{2,1};

an=sim(net,pn);
a(i,:)=mapminmax('reverse',an,ts);
```

```

resin(:,i)=T'-a(i,:);
[m1(i,:),a1(i,:),r1(i,:)] = postreg(a(i,:),T);

Q=data(ins+1:all,2:pred);
TQ=data(ins+1:all,1);
[qn,qns]=mapminmax(Q);
[tqn,tqs]=mapminmax(TQ);
bn=sim(net,qn);
b(i,:)=mapminmax('reverse',bn,tqs);
resout(:,i)=TQ'-b(i,:)'
[m2(i,:),b1(i,:),r2(i,:)] = postreg(b(i,:),TQ);

n(i,:)=i
k(i,:)=(size(bobotakhir_input,1)*size(bobotakhir_input,2))+(size(bobotakhir_bias_input,1)*size
(bobotakhir_bias_input,2))+(size(bobotakhir_lapisan1,1)*size(bobotakhir_lapisan1,2))+(size(bobotakhir_bias_lapisan1,1)*size(bobotakhir_bias_lapisan1,2));
pwr(i,:)=T'-a(i,:);
sigma_kwin(i,:)=mean(pwr(i,:).^2);
rmse_in(i,:)=sqrt(mean(resin(:,i).^2));
rmse_out(i,:)=sqrt(mean(resout(:,i).^2));
AIC(i,:)=log(sigma_kwin(i,:))+((n(i,:)+2*k(i,:))/n(i,:));
SBC(i,:)=log(sigma_kwin(i,:))+((k(i,:)*log(n(i,:)))/n(i,:));
MAPE(i,:)=mean(abs((TQ-b(i,:))./TQ))*100;
MAE(i,:)=mean(abs((TQ-b(i,:))));

end;
kriteria=[n k AIC SBC rmse_in MAPE rmse_out MAE]

```

Lampiran 4. Hasil Output ARIMA pada SAS

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.90489	0.03593	25.18	<.0001	1
MA1,2	-0.20788	0.03581	-5.81	<.0001	11
MA2,1	0.64303	0.11004	5.84	<.0001	12
AR1,1	0.27116	0.12681	2.14	0.0361	1
Variance Estimate				1.2957E8	
Std Error Estimate				11382.8	
AIC				1531.632	

SBC			1540.683						
Number of Residuals			71						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To	Chi-	Pr >							
Lag	Square	DF	ChiSq	-----Autocorrelations----					
6	2.66	2	0.2639	-0.033	0.061	0.076	-0.128	-0.079	0.036
12	6.49	8	0.5921	0.079	-0.176	0.066	-0.039	0.056	-0.005
18	9.97	14	0.7647	-0.025	0.121	-0.119	0.073	-0.054	0.003
24	12.71	0	0.8896	0.028	-0.106	0.089	-0.045	0.066	0.012
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.986164	Pr < W	0.6272					
Kolmogorov-Smirnov	D	0.061764	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.036295	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.223034	Pr > A-Sq	>0.2500					

DAFTAR PUSTAKA

- Suradnya, I. (2006). Analisis faktor-faktor daya tarik wisata bali dan implikasinya terhadap perencanaan pariwisata daerah bali. *ojs.unud.ac.id*, 2, 1-6.
- Sutiawan. (17 Desember 2012). 2013 pariwisata Bali diprediksi anjlok. *Metrobali*[online], Diambil 15 Oktober 2013, dari <http://metrobali.com/?p=18518>
- Sulistiyowati, A. (4 Maret 2013). Bali dan pariwisata yang tak mati. *Kompas*[online], Diambil 15 Oktober 2013, dari <http://travel.kompas.com/read/2013/03/04/09243719/Bali.dan.Pariwisata.yang.Tak.Mati>
- Cho, V. (2003). A comparison of three different approaches to tourist arrival forecasting. *Elsevier*, 4, 1–13.
- Zhang, G. P. (2003). Time Series Forecasting Using Hybrid ARIMA and Neural Network Model. *Journal of Neurocomputing*, 50, 159-175.
- Burger, C. J. S. C., Dohnal, M., Kathrada, M., & Law, R. (2001). A practitioners guide to time-series methods for tourism demand forecasting—a case study of Durban, South Africa. *Tourism management*, 22(4), 403-409.
- Suhartono. (2007). FeedForward Neural Networks untuk Pemodelan Runtun Waktu. Disertasi, Jurusan Matematika, Universitas Gadjah Mada.
- Saayman, A., & Saayman, M. (2010). Forecasting tourist arrivals in South Africa. *Acta Commercii*, 10, 281-293.
- Widyawati, K.A. (2013). *Prediksi Jumlah Penumpang Pesawat di Bandar Udara Internasional Ngurah Rai dengan Model Arima, Analisis Intervensi dan Pendekatan Perubahan Struktur*, Institut Teknologi Sepuluh November.
- Suhartono & Endharta, A. J. (2009). Short Term Electricity Load Demand Forecasting in Indonesia by Using Double Seasonal Recurrent Neural Networks. *International Journal of Mathematical Models and Methods In Applied Sciences*, 3 (3).

- Wei, W.W., (2006). *Time Series Analysis : Univariate and Multivariate Methods* (2nd ed.), Addison Wesley.
- Teräsvirta, T., Lin, C. F., & Granger, C. W. (1993). Power of the neural network linearity test. *Journal of Time Series Analysis*, 14(2), 209-218.
- Cryer, J. D. (1986). *Time series analysis*. Wadsworth Publ. Co..
- Bowman, B. L., & O'Connell, R. T. (1993). *Forecasting and time series: An applied approach* (Vol. 3). ^ eCalifornia California: Duxbury Press.
- Fausett, L., (1994). *Fundamentals of Neural Networks: Architecture, Algorithms, and Applications*, Prentice Hall.
- Haykin, S. (1994). *Neural Networks. A Comprehensive Foundation*. Macmillan, New York, NY.
- Chong, E.K.P. & Zak, S.H. (1996). *An Introduction to Optimization*. John Wiley & Sons, Inc., ISBN: 0-471-08949-4, New York, USA.

BIODATA PENULIS



Penulis bernama I Putu Prasetya Wikantara dilahirkan di Kabupaten Tabanan, Provinsi Bali pada tanggal 16 September 1992. Pendidikan formal yang pernah ditempuh penulis adalah TK Ora et Labora, SD Negeri 4 Dajan Peken Tabanan, dan SMA Negeri 1 Tabanan. Pada tahun 2010 Penulis melanjutkan pendidikan di Jurusan Statistika FMIPA ITS melalui jalur PKM Mandiri. Penulis tergabung dalam organisasi Tim Pembina Kerohanian Hindu (TPKH) ITS, dimana pada tahun 2011-2012 sebagai staff publikasi dan dokumentasi, dan tahun 2012-2013 sebagai staff departemen umum. Adapun *email* pribadi penulis, apabila pembaca ingin memberi kritik dan saran serta diskusi lebih lanjut mengenai Tugas Akhir ini, dapat diakses melalui iputu.prasetyaw@gmail.com.