



TUGAS AKHIR -SS141501

**PERAMALAN JUMLAH PENUMPANG
KERETA API KELAS EKONOMI KERTAJAYA
MENGGUNAKAN ARIMA DAN ANFIS**

ILAFI ANDALITA
NRP 1311 100 038

Dosen Pembimbing
Dr. Irhamah, M.Si.

Program Studi S-1 Statistika
Fakultas Matematika Dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2015



TUGAS AKHIR -SS141501

**PERAMALAN JUMLAH PENUMPANG
KERETA API KELAS EKONOMI KERTAJAYA
MENGGUNAKAN ARIMA DAN ANFIS**

**ILAFI ANDALITA
NRP 1311 100 038**

**Dosen Pembimbing
Dr. Irhamah, M.Si.**

**Program Studi S-1 Statistika
Fakultas Matematika Dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2015**



FINAL PROJECT -SS141501

**FORECASTING PASSENGER VOLUME
OF ECONOMY CLASS TRAIN KERTAJAYA
USING ARIMA AND ANFIS**

**ILAFI ANDALITA
NRP 1311 100 038**

**Supervisor
Dr. Irhamah, M.Si.**

**Undergraduate Programme of Statistics
Faculty Of Mathematics And Natural Sciences
Institut Teknologi Sepuluh Nopember
Surabaya 2015**

LEMBAR PENGESAHAN

PERAMALAN JUMLAH PENUMPANG KERETA API KELAS EKONOMI KERTAJAYA MENGGUNAKAN ARIMA DAN ANFIS

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 :

ILAFI ANDALITA
NRP. 1311 100 038

Disetujui oleh Pembimbing Tugas Akhir:

Dr. Irhamah, M.Si.
NIP. 19780406 200112 2 002

(*[Signature]*)

Mengetahui
Ketua Jurusan Statistika FMIPA-ITS



JURUSAN
STATISTIKA
Dr. Muhammad Mashuri, MT
NIP. 19620408 198701 1 001

SURABAYA, JULI 2015

PERAMALAN JUMLAH PENUMPANG KERETA API KELAS EKONOMI KERTAJAYA MENGGUNAKAN ARIMA DAN ANFIS

Nama : Ilafi Andalita
NRP : 1311 100 038
Jurusan : Statistika FMIPA-ITS
Dosen Pembimbing : Dr.Irhamah, M.Si.

ABSTRAK

Peramalan jumlah penumpang kereta api kelas ekonomi Kertajaya merupakan salah satu upaya penting untuk mengetahui kebutuhan pengguna transportasi tersebut. Namun, time series jumlah penumpang kereta api Kertajaya yang mempunyai fluktiasi tinggi terbukti bersifat nonlinear berdasarkan uji linieritas. Pemodelan menggunakan pendekatan linier seperti ARIMA Box-Jenkins tidak selalu memberikan peramalan yang baik karena terikat beberapa asumsi dalam membangun model. Oleh karena itu penelitian ini mengusulkan penggunaan metode ANFIS yang diharapkan memberikan kinerja lebih baik dalam pemodelan nonlinier dan dibandingkan dengan hasil dari ARIMA. Penggunaan ANFIS untuk peramalan jumlah penumpang selama 14 periode ke depan memberikan akurasi ramalan yang lebih tinggi daripada ARIMA karena MAPE dan RMSE yang dihasilkan lebih kecil. Model ANFIS terbaik dihasilkan dari input jumlah penumpang pada satu, tujuh, dan delapan hari sebelumnya dan fungsi keanggotaan pi.

Kata Kunci: ARIMA, ANFIS, jumlah penumpang, nonlinier

Halaman ini sengaja dikosongkan

FORECASTING PASSENGER VOLUME OF ECONOMY CLASS TRAIN KERTAJAYA USING ARIMA AND ANFIS

Name	: Ilafi Andalita
NRP	: 1311100038
Department	: Statistika FMIPA-ITS
Supervisor	: Dr. Irhamah M.Si.

ABSTRACT

Forecasting the passenger volume of economy class train Kertajaya is essential to know the needs of transport users. However, time series of passenger volume from Kertajaya train which has a high fluctuation is proved to be nonlinear based on linearity test. Modeling using linear approach such as Box-Jenkins ARIMA model not always performs better because it's bound some assumptions to build the model. Therefore, this study proposes ANFIS model that is expected can yields better performance in modeling nonlinear time series and compared with the results of ARIMA. Using ANFIS for forecasting the passenger volume during the 14 periods aheads yields a higher accuracy of forecasts than ARIMA because it gives smaller MAPE and RMSE. The best ANFIS model is generated from the input of passenger volume on one day, seven and eight days before and the membership function of p_i .

Key Word : ARIMA, ANFIS , passenger volume, nonlinier

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Dengan Nama Allah Yang Maha Pengasih lagi Maha Penyayang.

Segala puji bagi Allah yang telah melimpahkan rahmat dan hidayah, sehingga Penulis dapat menyelesaikan dengan baik Laporan Tugas Akhir yang berjudul

**“Peramalan Jumlah Penumpang
Kereta Api Kelas Ekonomi Kertajaya
menggunakan ARIMA dan ANFIS”**

sebagai salah satu syarat yang harus dipenuhi untuk menyelesaikan pendidikan sarjana sesuai kurikulum pada Program Studi S-1 Statistika FMIPA-ITS dan memperoleh Gelar Sarjana Sains.

Selama perkuliahan hingga penyusunan Laporan Tugas Akhir ini, Penulis ingin mengucapkan terima kasih kepada:

1. Dr. Muhammad Mashuri, M.T selaku Ketua Jurusan Statistika FMIPA ITS sekaligus dosen wali yang telah dianggap Penulis sebagai panutan, inspirasi, dan pemimpin selama ini.
2. Dra. Lucia Aridinanti, M.T. selaku koordinator program studi S-1 Statistika yang telah memberikan kritik dan saran atas Laporan Tugas Akhir ini.
3. Dr. Santi Wulan Purnami, M.Si. selaku Sekretaris Program Studi S-1 yang telah memberikan kesabaran dalam proses penyelesaian Laporan Tugas Akhir ini.
4. Dr. Brodjol Sutijo Suprih Ulama, M.Si. selaku Ketua Laboratorium Komputasi Program Studi S-1 Statistika.
5. Dr. Irhamah, M.Si. selaku selaku dosen pembimbing atas semua inspirasi, perhatian, kesabaran, dan waktu dalam membimbing Penulis hingga menyelesaikan Laporan Tugas Akhir.
6. Dra. Wiwiek Setya Winahju, M.S. dan Ir. Dwiatmono Agus W., MIKom selaku dosen penguji yang telah memberikan kritik dan saran sedemikian hingga Penulis selalu terpacu untuk menyelesaikan Laporan Tugas Akhir dengan sebaik-baiknya.

7. Seluruh Dosen Jurusan Statistika FMIPA ITS yang telah memberikan ilmu yang tiada bernilai harganya dan segenap Bapak/ Ibu Karyawan Jurusan Statistika FMIPA ITS.
8. Ayah, Mama, Mas Wega, dan keluarga tercinta yang senantiasa mendoakan dan memberikan kasih sayang serta dukungan baik moril maupun material kepada penulis agar selalu berusaha dan melakukan yang terbaik.
9. Teman sekaligus keluarga statistika angkatan 2011 yang selama ini menjadi tempat berbagi ilmu yang bermanfaat. Keluarga statistika angkatan 2008, 2009, dan 2010 yang telah memberikan didikan, cerita, bantuan, dan inspirasi bagi Penulis serta tak lupa untuk angkatan 2012 dan 2013 berusahalah kita untuk lebih baik sebagai generasi.
10. Aul, Eyon, Elika, Silvi, Saidah, Masyitha, Dio, Jo, Tika, Ladayya, Chus, Nimas, Indah, dan Ririn, berbeda karakter bisa menjadi pembelajaran. DAGRI, Keluarga PSDM, dan Ekspre-six yang telah memberikan pembelajaran bagi Penulis untuk menjadi teman, sahabat, dan Pemimpin yang baik.
11. Ririn, Boz, Fiscy, April, Annisa atas suka cita dan berbagi apa saja serta keluarga kost. Semoga kita selalu berbahagia.
12. Tim PKM yang entah takdir apa sehingga bisa bertemu dan semoga berprestasi selalu.

Semoga Laporan Tugas Akhir ini bermanfaat bagi Pembaca. Penulis menyadari bahwa laporan ini masih jauh dari suatu kesempurnaan oleh karena itu, kritik dan saran diharapkan dapat diberikan dari semua pihak untuk tahap pengembangan selanjutnya.

Surabaya, Juli 2015

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
TITLE PAGE	iii
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR TABEL	xix
DAFTAR GAMBAR	xxiii
DAFTAR LAMPIRAN	xxv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	5
1.3 Tujuan Penelitian	6
1.4 Manfaat Penelitian	6
1.5 Batasan Masalah	6
BAB II TINJAUAN PUSTAKA	7
2.1 Perkeretaapian Indonesia	7
2.2 <i>Time Series</i>	11
2.3 Prosedur ARIMA Box-Jenkins	11
2.3.1 Identifikasi Model	11
2.3.2 Estimasi Parameter	14
2.3.3 Pemeriksaan Diagnostik	18
2.3.4 Pemilihan Model Terbaik	19
2.4 Model <i>Autoregressive Integrated Moving Average</i> (ARIMA)	20
2.5 Deteksi <i>Outlier</i>	21
2.6 Pengujian Linieritas	24
2.7 <i>Soft Computing</i>	25
2.7.1 Teori Himpunan Fuzzy	26
2.7.2 Model <i>Adaptive Neuro Fuzzy Inference System</i>	29

BAB III METODOLOGI PENELITIAN.....	35
3.1 Sumber Data dan Variabel Penelitian	35
3.2 Langkah –langkah Analisis	35
BAB IV ANALISIS DAN PEMBAHASAN.....	41
4.1 Eksplorasi Data Jumlah Penumpang Kereta Api Kertajaya	41
4.2 Peramalan Jumlah Penumpang Kereta Api Kertajaya	46
4.2.1 Identifikasi Model ARIMA untuk Memramalkan Jumlah Penumpang Kereta Api Kertajaya.....	46
4.2.2 Estimasi Parameter Model ARIMA	51
4.2.3 Pemeriksaan Diagnostik terhadap Residual Model ARIMA	53
4.2.4 Deteksi <i>Outlier</i> pada Model ARIMA	55
4.2.5 Pemilihan Model ARIMA Terbaik.....	61
4.3 Pemodelan Jumlah Penumpang Kereta Api Kertajaya Menggunakan ANFIS.....	64
4.3.1 Proses pada Lapisan ke-1 Arsitektur AN-FIS	66
4.3.2 Proses pada Lapisan ke-2 Arsitektur AN-FIS	76
4.3.3 Proses pada Lapisan ke-3 Arsitektur AN-FIS	80
4.3.4 Proses pada Lapisan ke-4 Arsitektur AN-FIS	84
4.3.5 Proses pada Lapisan ke-5 Arsitektur AN-FIS	89
4.3.6 Perbandingan Pemodelan ANFIS	90
4.4 Perbandingan Pemodelan ARIMA dan ANFIS	93
BAB V KESIMPULAN DAN SARAN.....	97
5.1 Kesimpulan.....	97
5.2 Saran.....	98

DAFTAR PUSTAKA	99
LAMPIRAN.....	103

Halaman ini sengaja dikosongkan

DAFTAR TABEL

	Halaman
Tabel 2.1	Tarif Kereta Ekonomi yang disesuaikan.....9
Tabel 2.2	Hari Libur Nasional dan Cuti Bersema Tahun 2014 dan 2015.....10
Tabel 2.3	Nilai Lambda Umum yang dinakan dan Transfor- masi Terkait12
Tabel 2.4	Karakteristik Teoritis ACF dan PACF untuk Pro- ses yang Stasioner.....14
Tabel 2.5	Hipotesis dan Statistik Uji untuk Signifikansi Pa- rameter17
Tabel 4.1	Statistika Deskriptif Data Jumlah Penumpang Berdasarkan Hari41
Tabel 4.2	Statistika Deskriptif Data Jumlah Penumpang Berdasarkan Bulan43
Tabel 4.3	Signifikansi Parameter untuk Model ARIMA ([1,2,3,6],1,1) (0,1,1) ⁷51
Tabel 4.4	Signifikansi Parameter Model ARIMA ([4,6],1,1) (0,1,1) ⁷52
Tabel 4.5	Signifikansi Parameter Model ARIMA (0,1,[1,4]) (0,1,1) ⁷52
Tabel 4.6	Pemeriksaan Diagnostik <i>White Noise</i> terhadap Residual Model ARIMA ([1,2,3,6],1,1) (0,1,1) ⁷53
Tabel 4.7	Pemeriksaan Diagnostik <i>White Noise</i> terhadap Residual Model ARIMA ([4,6],1,1) (0,1,1) ⁷54
Tabel 4.8	Pemeriksaan Diagnostik <i>White Noise</i> terhadap Residual Model ARIMA (0,1,[1,4]) (0,1,1) ⁷54
Tabel 4.9	Pemeriksaan Diagnostik Distribusi Normal.....55
Tabel 4.10	Signifikansi Parameter untuk Model ARIMA ([1,2,3,6],1,1) (0,1,1) ⁷ dengan Deteksi <i>Outlier</i>56
Tabel 4.11	Signifikansi Parameter Model ARIMA ([4,6],1,1) (0,1,1) ⁷ dengan Deteksi <i>Outlier</i>57
Tabel 4.12	Signifikansi Parameter Model ARIMA (0,1,[1,4]) (0,1,1) ⁷ dengan Deteksi <i>Outlier</i>58

Tabel 4.13	Pemilihan Model Terbaik Berdasarkan Kriteria Kebaikan Model	62
Tabel 4.14	Hasil Uji Linieritas.....	64
Tabel 4.15	Kombinasi Variabel <i>Input</i>	65
Tabel 4.16	<i>Input Data In-sample</i>	66
Tabel 4.17	Parameter Nonlinier Fungsi Keanggotaan <i>Gaussian</i>	67
Tabel 4.18	Parameter Nonlinier Fungsi Keanggotaan <i>Generalized bell</i>	67
Tabel 4.19	Parameter Nonlinier Fungsi Keanggotaan <i>Trapezoidal</i> ...	68
Tabel 4.20	Parameter Nonlinier Fungsi Keanggotaan <i>Triangular</i>	68
Tabel 4.21	Parameter Nonlinier Fungsi Keanggotaan <i>Pi</i>	68
Tabel 4.22	<i>Output</i> Lapisan ke-1 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Gaussian</i>	74
Tabel 4.23	<i>Output</i> Lapisan ke-1 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Generalized Bell</i>	75
Tabel 4.24	<i>Output</i> Lapisan ke-1 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Trapezoidal</i>	75
Tabel 4.25	<i>Output</i> Lapisan ke-1 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Triangular</i>	75
Tabel 4.26	<i>Output</i> Lapisan ke-1 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Pi</i>	76
Tabel 4.27	<i>Output</i> Lapisan ke-2 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Gaussian</i>	77
Tabel 4.28	<i>Output</i> Lapisan ke-2 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Generalized Bell</i>	78
Tabel 4.29	<i>Output</i> Lapisan ke-2 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Trapezoidal</i>	78
Tabel 4.30	<i>Output</i> Lapisan ke-2 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Triangular</i>	79
Tabel 4.31	<i>Output</i> Lapisan ke-2 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Pi</i>	80
Tabel 4.32	<i>Output</i> Lapisan ke-3 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Gaussian</i>	81
Tabel 4.33	<i>Output</i> Lapisan ke-3 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Generalized Bell</i>	81

Tabel 4.34	<i>Output</i> Lapisan ke-3 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Trapezoidal</i>	82
Tabel 4.35	<i>Output</i> Lapisan ke-3 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Triangular</i>	83
Tabel 4.36	<i>Output</i> Lapisan ke-3 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Pi</i>	83
Tabel 4.37	Parameter Linier pada Fungsi Keanggotaan <i>Gaussian</i>	84
Tabel 4.38	Parameter Linier pada Fungsi Keanggotaan <i>Generalized bell</i>	85
Tabel 4.39	Parameter Linier pada Fungsi Keanggotaan <i>Trapezoidal</i>	85
Tabel 4.40	Parameter Linier pada Fungsi Keanggotaan <i>Triangular</i> ..	85
Tabel 4.41	Parameter Linier pada Fungsi Keanggotaan <i>Pi</i>	86
Tabel 4.42	<i>Output</i> Lapisan ke-4 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Gaussian</i>	86
Tabel 4.43	<i>Output</i> Lapisan ke-4 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Generalized Bell</i>	87
Tabel 4.44	<i>Output</i> Lapisan ke-4 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Trapezoidal</i>	87
Tabel 4.45	<i>Output</i> Lapisan ke-4 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Triangular</i>	88
Tabel 4.46	<i>Output</i> Lapisan ke-4 pada Pemodelan ANFIS Fungsi Keanggotaan <i>Pi</i>	90
Tabel 4.47	<i>Output</i> dari Lapisan ke-5	90
Tabel 4.48	Perbandingan RMSE Kebaikan Model untuk <i>In-sample</i>	90
Tabel 4.49	Perbandingan Kriteria Kebaikan Model untuk <i>Out-sample</i>	92
Tabel 4.50	Perbandingan Kriteria Kebaikan Model untuk <i>Out-sample</i> pada Model ANFIS dan ARIMA.....	94
Tabel 4.51	Peramalan <i>Out-sample</i> oleh Model ARIMA dan ANFIS	95

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

	Halaman	
Gambar 2.1	Bentuk Fungsi Keanggotaan.....	29
Gambar 2.2	Arsitektur ANFIS yang setara	31
Gambar 3.1	Diagram Alir Pemodelan ARIMA.....	37
Gambar 3.2	Diagram Alir Uji Linieritas	38
Gambar 3.3	Diagram Alir Pemodelan ANFIS.....	39
Gambar 4.1	<i>Boxplot</i> Data Jumlah Penumpang Berdasarkan Hari	42
Gambar 4.2	<i>Boxplot</i> Data Jumlah Penumpang Berdasarkan Bulan.....	45
Gambar 4.3	Plot <i>Time Series</i> Jumlah Penumpang Kereta A- pi Kertajaya.....	47
Gambar 4.4	Plot <i>Box-Cox</i> Data Jumlah Penumpang	48
Gambar 4.5	Plot ACF dan PACF Data Jumlah Penumpang	49
Gambar 4.6	Plot ACF dan PACF Data Jumlah Penumpang dengan Pembedaan $(1-B^7)Z_t$	50
Gambar 4.7	Plot ACF dan PACF Data Jumlah Penumpang dengan Pembedaan $(1-B)(1-B^7)Z_t$	51
Gambar 4.8	Ringkasan Grafis pada Residual Model ARI- MA	60
Gambar 4.9	Perbandingan Data <i>Out-sample</i> dengan Hasil Peramalan Keenam Model ARIMA	62
Gambar 4.10	Asitektur ANFIS dengan Tiga <i>Input</i> dan Dela- pan Aturan	66
Gambar 4.11	Plot Individual RMSE <i>In-sample</i> Berdasarkan Fungsi Keanggotaan	91
Gambar 4.12	Plot Individual MAPE <i>Out-sample</i> Berdasar- kan Fungsi Keanggotaan.....	92
Gambar 4.13	Plot <i>Time Series</i> Perbandingan Peramalan ANFIS dan Data Asli.....	93
Gambar 4.14	Plot <i>Time Series</i> Perbandingan Peramalan AN- FIS, ARIMA, dan Data Asli	94

Halaman ini sengaja dikosongkan

DAFTAR LAMPIRAN

	Halaman	
Lampiran 1	Data Jumlah Penumpang Kereta Api Ekonomi Kertajaya.....	103
Lampiran 2	Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([1,2,3,6],1,1) (0,1,1) ⁷	104
Lampiran 3	Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1) ⁷	105
Lampiran 4	Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA (0,1,[1,4]) (0,1,1) ⁷	106
Lampiran 5	Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA (1,0,1) (0,1,1) ⁷	107
Lampiran 6	Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA (1,0,[2]) (0,1,1) ⁷	108
Lampiran 7	Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([2,0,[14]] (1,1,0) ⁷ ...	109
Lampiran 8	Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([1,2,3,6],1,1) (0,1,1) ⁷ dengan Deteksi <i>Outlier</i>	110
Lampiran 9	Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1) ⁷ dengan Deteksi <i>Outlier</i>	111
Lampiran 10	Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA (0,1, [1,4]) (0,1,1) ⁷ dengan Deteksi <i>Outlier</i>	113
Lampiran 11	Hasil Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1) ⁷	114
Lampiran 12	Hasil Peramalan Jumlah Penumpang menggunakan ARIMA (0,1, [1,4]) (0,1,1) ⁷	116

Lampiran 13	Hasil Peramalan Jumlah Penumpang menggunakan ARIMA ([1,2,3,6],1,1) (0,1,1) ⁷ dengan Deteksi <i>Outlier</i>	118
Lampiran 14	Hasil Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1) ⁷ dengan Deteksi <i>Outlier</i>	120
Lampiran 15	Hasil Peramalan Jumlah Penumpang menggunakan ARIMA (0,1, [1,4]) (0,1,1) ⁷ dengan Deteksi <i>Outlier</i>	122
Lampiran 16	Program R dan Hasil untuk Uji <i>Terasvirta</i> dan <i>White</i>	124
Lampiran 17	Program Pemodelan ANFIS dengan <i>Gbellmf</i> Menggunakan Matlab.....	125
Lampiran 18	Hasil dari Pemodelan ANFIS dengan <i>Gbellmf</i> Menggunakan Matlab	126
Lampiran 19	Program Pemodelan ANFIS dengan <i>Gaussmf</i> Menggunakan Matlab.....	132
Lampiran 20	Hasil dari Pemodelan ANFIS dengan <i>Gaussmf</i> Menggunakan Matlab	133
Lampiran 21	Program Pemodelan ANFIS dengan <i>Trapmf</i> Menggunakan Matlab	139
Lampiran 22	Hasil dari Pemodelan ANFIS dengan <i>Trapmf</i> Menggunakan Matlab.....	140
Lampiran 23	Program Pemodelan ANFIS dengan <i>Trimf</i> Menggunakan Matlab	146
Lampiran 24	Hasil dari Pemodelan ANFIS dengan <i>Trimf</i> Menggunakan Matlab	140
Lampiran 25	Program Pemodelan ANFIS dengan <i>Pimf</i> Menggunakan Matlab	153
Lampiran 26	Hasil Pemodelan ANFIS dengan <i>Pimf</i> Menggunakan Matlab	154

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kereta api merupakan salah satu alat transportasi yang diminati masyarakat dan memiliki kapasitas besar dalam mengangkut penumpang atau dapat disebut pula alat transportasi massal. Badan Pusat Statistik (2014) menyebutkan terjadi peningkatan jumlah penumpang kereta api di Jawa dan Sumatera. Jumlah penumpang kereta api kumulatif pada Januari s.d Agustus 2014 mencapai 178 juta orang atau meningkat sebesar 32.44 % bila dibandingkan dengan periode yang sama pada tahun 2013. Kenaikan jumlah penumpang kereta api terjadi pada seluruh wilayah yaitu: Jabodetabek, Jawa non-Jabodetabek, dan Sumatera. Adapun masing-masing wilayah naik sebesar 37.35 %, 19.53%, dan 25.62 %. Badan Usaha Milik Negara (BUMN) yang menyelenggarakan jasa angkutan kereta api adalah PT Kereta Api Indonesia (PT. KAI). PT. KAI berkewajiban menyelenggarakan *Public Service Obligation* (PSO) yaitu salah satunya dengan memberikan subsidi kepada beberapa kereta api. PT. KAI (2014) memprioritaskan KRL dan KA ekonomi jarak dekat untuk pemberian subsidi. Hal ini mengakibatkan tarif untuk KA Ekonomi Jarak Jauh mengalami beberapa perubahan tarif sepanjang tahun 2014 hingga tahun 2015. Salah satu kereta api kelas ekonomi yang menempuh perjalanan dengan jarak jauh adalah kereta api Kertajaya.

Kereta api Kertajaya mengangkut penumpang yang memiliki tujuan Surabaya-Jakarta atau sebaliknya. Selama tahun 2014, Kereta api Kertajaya mengalami beberapa penyesuaian tarif tiket seperti halnya kereta ekonomi jarak jauh yang lain. Tarif kereta api ekonomi jarak jauh pada Bulan Januari 2014 diputuskan untuk be-

ubah menjadi tarif nonsubsidi hingga pada Bulan April 2014 tarif berubah menjadi tarif bersubsidi. Pada Bulan September 2014 diumumkan bahwa tarif kereta api ekonomi jarak jauh akan mengalami perubahan menjadi tarif nonsubsidi. Namun perubahan tarif pada Bulan September 2014 tersebut batal sehingga pada Bulan September 2014 masyarakat masih menikmati tarif bersubsidi. Perubahan tarif yang berkali-kali dalam satu tahun mulai dari tarif yang bersubsidi hingga tarif nonsubsidi membuat pengguna jasa transportasi tersebut masih belum terbiasa dengan kondisi tersebut. Hal tersebut berakibat pada jumlah penumpang kereta api yang berfluktuatif di sepanjang tahun 2014 meskipun secara umum jumlah penumpang kereta api meningkat. Demi melihat kebutuhan akan alat transportasi kereta api, maka perlu untuk meramalkan jumlah penumpang kereta api. Adanya peramalan jumlah penumpang memberikan cerminan dari kebutuhan masyarakat terhadap alat transportasi kereta api dan agar dapat dilakukan peningkatan sarana dan prasarana berkenaan dengan perkeretaapian khususnya pada kereta api Kertajaya. Namun data jumlah penumpang kereta api kertajaya mulai Mei 2014 sampai dengan Mei 2015 tergolong sebagai *time series* yang nonlinier berdasarkan uji linieritas.

Penelitian yang berkaitan dengan peramalan jumlah penumpang kereta api telah banyak dilakukan oleh beberapa peneliti. Salah satunya adalah Widiyanto (2013) yang meramalkan jumlah penumpang Kereta Api Logawa dan Sritanjung menggunakan prosedur Box Jenkins dan regresi *time series* dengan efek variasi kalender. Penelitian tersebut memberikan hasil bahwa peramalan menggunakan metode regresi *time series* dengan efek variasi kalender lebih baik. Selain itu, penelitian dengan metode sejenis pernah dilakukan oleh Widhianti dan Wutaqa (2013) dengan meramalkan banyak penumpang kereta DAOP VI Yogyakarta dan

memberikan hasil bahwa model penggabungan model ARIMA dan regresi *time series* dengan efek variasi kalender signifikan. Padang, Tarigan, dan Sinulingga (2013) juga melakukan peramalan terhadap jumlah penumpang kereta api Medan-Rantau Prapat dengan Metode Pemulusan Eksponensial Holt-Winters. Penelitian-penelitian tersebut merupakan beberapa contoh suatu peramalan yang menggunakan pendekatan linier. Namun, kondisi tertentu membuat beberapa peramalan dengan pendekatan linier menjadi sulit untuk diterapkan seperti kondisi yang terjadi pada jumlah penumpang kereta api Kertajaya yang berupa data nonlinier. Adapun metode alternatif yang dapat digunakan selain dengan pendekatan linier adalah dengan menggunakan pendekatan *soft computing*. Penggunaan *soft computing* sebagai metode alternatif dari pendekatan linier memiliki kelebihan yaitu dapat digunakan untuk menganalisis *time series* yang nonlinier.

Soft computing adalah suatu model pendekatan untuk melakukan komputasi dengan meniru akal manusia dan memiliki kemampuan untuk menalar dan belajar pada lingkungan yang penuh dengan ketidakpastian dan ketidaktepatan (Zadeh, 1992). *Soft computing* terdiri dari beberapa komponen atau kerangka bernalar yaitu jaringan syaraf (*neural network*), sistem fuzzy, penalaran dengan probabilitas, dan optimasi derivatif bebas seperti algoritma genetika. Komponen-komponen tersebut memiliki kelebihan masing-masing. Integrasi dari komponen-komponen tersebut menghasilkan algoritma yang lebih baik dalam merancang suatu sistem kecerdasan, salah satunya adalah *neuro-fuzzy computation*. Adapun pemodelan *neuro-fuzzy* adalah *Adaptive Neuro Fuzzy Inference System* atau disebut ANFIS (Jang , Sun, & Mizutani, 1997). ANFIS memiliki arsitektur dari kedua komponen *soft computing* yaitu jaringan syaraf tiruan dan sistem/ logika fuzzy, sehingga AN-

FIS memiliki kelebihan yang dimiliki oleh kedua komponen tersebut (Avci, 2008).

ANFIS telah digunakan dalam berbagai penelitian salah satunya adalah untuk peramalan. Peramalan indeks harga saham TAIEX yang dilakukan oleh Cheng, Wei, dan Chen (2009) menggunakan metode ANFIS dengan input indeks harga saham tersebut. Adapun hasil penelitian menyebutkan bahwa model ANFIS dapat digunakan untuk meramalkan indeks harga saham dan memiliki RMSE kecil. Selain itu, ANFIS dapat menggunakan input dari pemodelan statistik yaitu penelitian oleh Nurvitasisari (2012) menggunakan metode ANFIS dengan input dari fungsi transfer untuk meramalkan kecepatan angin rata-rata harian di Sumenep. Varedi (2011) menerapkan metode ANFIS untuk mengembangkan model perbandingan untuk mempelajari pengaruh penjualan kursi penumpang pesawat satu arah dan pulang pergi dan MAPE dari model adalah $<5\%$. Penelitian lain berasal dari Gyu-jin, Jin-pyung, Jee-hyong, & Moon-hyun (2011) mengenai peramalan jangka pendek terhadap jumlah penumpang kereta pada dua terminal metropolitan Korea. Hasil penelitian menyebutkan bahwa model memiliki akurasi $>93\%$. Selain itu penelitian untuk membandingkan metode ANFIS dan Box-Jenkins telah dilakukan oleh Atsalakis, Nezis, dan Matalliotakis (2008) yaitu peramalan tingkat kematian di Amerika. Penelitian tersebut menghasilkan kesimpulan bahwa model ANFIS memberikan hasil yang lebih baik daripada model AR dan ARIMA. Perbandingan model ARIMA dan ANFIS juga pernah dilakukan oleh Galavi, Mirzaei, Shui, dan Valizadeh (2013) dengan meramalkan ketinggian air di Sungai Klang Malaysia. Analisis menunjukkan bahwa hasil peramalan dengan menggunakan kedua model memiliki nilai MAPE sebesar $<0.5\%$ namun model ARIMA memberikan nilai yang lebih kecil. ARIMA memberikan MAPE yang lebih kecil karena Galavi et al. (2013)

melakukan pembaharuan pada data pengamatan pada setiap peramalan (satu periode peramalan) sehingga data pengamatan terbaru dimasukkan pada database model ARIMA. Adapula Yayar, Hekim, Yilmaz, & Bakirci (2011) meramalkan konsumsi beban listrik di Provinsi Tokat, Turi menggunakan ANFIS dan membandingkannya dengan model ARIMA. Hasil penelitian menunjukkan bahwa model ANFIS lebih tepat untuk meramalkan konsumsi listrik di wilayah tersebut.

Berdasarkan kondisi jumlah penumpang kereta api ekonomi jarak jauh khususnya Kereta Api Kertajaya dan berbagai penelitian terdahulu, maka peneliti menerapkan model ANFIS sebagai metode peramalan. Adapun metode ANFIS menggunakan *input* dari pendekatan ARIMA. Hasil pemodelan ANFIS dibandingkan dengan ARIMA untuk meramalkan jumlah penumpang Kereta Api Kertajaya. Penelitian ini diharapkan dapat memberikan alternatif metode yang digunakan untuk meramalkan jumlah penumpang.

1.2 Perumusan Masalah

Kebutuhan masyarakat terhadap mode transportasi kereta api kelas ekonomi Kertajaya dapat diketahui salah satunya dengan peramalan jumlah penumpang. Namun jumlah penumpang kereta api Kertajaya mulai Bulan Mei 2014 sampai dengan Mei 2015 cenderung fluktuatif dan termasuk ke dalam *time series* yang nonlinier. Peramalan menggunakan pendekatan linier yaitu ARIMA Box-Jenkins membutuhkan beberapa asumsi untuk membangun model, sehingga sulit bila digunakan untuk meramalkan *time series* yang nonlinier. Adapun alternatif metode untuk peramalan adalah ANFIS yang merupakan salah satu teknik *soft computing* yang dapat digunakan untuk menganalisis *time series* yang nonlinier. Penelitian ini akan menerapkan metode ANFIS untuk meramalkan

jumlah penumpang dan membandingkannya dengan pendekatan linier yaitu ARIMA Box-jenkins.

1.3 Tujuan Penelitian

Berikut ini merupakan tujuan yang ingin dicapai dalam penelitian ini.

1. Mengetahui karakteristik jumlah penumpang berdasarkan eksplorasi data.
2. Meramalkan jumlah penumpang Kereta Api Ekonomi Kertajaya dengan pendekatan linier yaitu ARIMA Box-Jenkins.
3. Menerapkan teknik *soft computing* yaitu ANFIS untuk meramalkan jumlah penumpang Kereta Api Ekonomi Kertajaya yang merupakan *time series* yang nonlinier.
4. Melakukan perbandingan model dari pendekatan linier dan teknik *soft computing* yaitu model ARIMA Box-Jenkins dan ANFIS serta memperoleh model yang terbaik.

1.4 Manfaat Penelitian

Manfaat yang dapat diperoleh dari adanya penelitian ini adalah sebagai berikut.

1. Memberikan informasi tertulis kepada PT.KAI DAOP VIII Surabaya atas hasil penelitian.
2. Menerapkan teknik *soft computing* sebagai alternatif dari pendekatan linier.

1.5 Batasan Masalah

Penelitian ini dilakukan terhadap data jumlah penumpang harian Kereta Api Ekonomi Kertajaya yang beroperasi pada jalur Surabaya-Jakarta (pemberangkatan dari Stasiun Pasar Turi, Surabaya dengan pemberhentian di Stasiun Pasar Senin, Jakarta).

BAB II

TINJAUAN PUSTAKA

Bab II berisi mengenai referensi yang digunakan pada penelitian ini. Adapun tinjauan pustaka terdiri dari sejarah perkeretaapian Indonesia beserta tarif kereta api ekonomi yang mengalami penyesuaian dan referensi mengenai analisis *time series* menggunakan dua pendekatan yaitu pendekatan linier menggunakan prosedur ARIMA Box-Jenkins dan pendekatan *soft computing* menggunakan ANFIS.

2.1 Perkeretaapian Indonesia

Badan Usaha Milik Negara (BUMN) yang menyediakan, mengatur, dan mengurus jasa angkutan kereta api di Indonesia adalah PT Kereta Api Indonesia (Persero). PT Kereta Api Indonesia didirikan pada tanggal 1 Juni 1999. Sejak pertama kali berdiri hingga periode sekarang, sejarah PT Kereta Api Indonesia dibagi menjadi tiga periode, yaitu masa kolonial, sebagai lembaga pelayanan publik, dan sebagai perusahaan jasa. Sejarah perkera-
taapian pada masa kolonial dimulai pada tahun 1864 ketika Nam-
looze Venootschap Nederlische Spoorweg Maatschappij memprakarsai pembangunan jalan kereta api dari Semarang ke Surakarta, Jawa Tengah. Sejak itu beberapa perusahaan lain ber-
investasi membangun jalur-jalur kereta api di dalam dan luar Pu-
lau Jawa.

Orientasi perusahaan sebagai lembaga pelayanan publik berawal pada awal kemerdekaan Indonesia. Berdasarkan Peraturan Pemerintah No. 22 Tahun 1963, pada tanggal 25 Mei pemerintah Republik Indonesia membentuk Perusahaan Negara Kereta Api (PNKA). Pada 15 September 1997 berdasarkan Peraturan Pemerintah No. 61 Tahun 1971, PNKA diubah menjadi Perusahaan Jawatan Kereta Api (PJKA). Dengan status sebagai Perusahaan Negara dan Perusahaan Jawatan, PT Kereta Api Indonesia (Persero) saat itu beroperasi melayani masyarakat dengan dana subsidi dari pemerintah.

Pengelolaan PT Kereta Api Indonesia (Persero) dimulai ketika dikeluarkannya Peraturan Pemerintah No. 57 tahun 1990 tentang PJKA diubah menjadi Perusahaan Umum Kereta Api (Perumka). Status baru Perumka sebagai perusahaan umum membuat perusahaan tersebut berupaya untuk mendapatkan laba dari jasa yang disediakannya. Perumka menawarkan tiga kelas layanan, yaitu kelas eksekutif, bisnis, dan ekonomi. Upaya pemerintah menjadikan Perumka menjadi perusahaan bisnis jasa direalisasikan pada tanggal 3 Februari 1998 dengan menetapkan bentuk Perusahaan Umum Kereta Api (Perumka) menjadi Perusahaan Persero (persero) berdasarkan Peraturan Pemerintah No. 19 Tahun 1998. PT Kereta Api Indonesia beroperasi sebagai lembaga bisnis yang berorientasi laba. Sebagai organisasi pelayanan publik, pemerintah menyediakan dana *Public Service Obligation* (PSO).

Adapun PT. KAI memiliki pelayanan kereta api di sembilan Daerah Operasional (DAO) yang tersebar di Jawa dan tiga Divisi Regional (Divre) yang tesebar di Sumatera. Perusahaan yang memiliki visi “Menjadi Penyedia Jasa Perkeretaapian Terbaik yang Fokus pada Pelayanan Pelanggan dan Memenuhi Harapan Stakeholders” mengoperasikan kereta api eksekutif, bisnis, dan ekonomi. PT. KAI (2014) memprioritaskan KRL dan KA ekonomi jarak dekat untuk pemberian subsidi sehingga KA Ekonomi mengalami beberapa perubahan tarif atau penyesuaian tarif. Empat faktor utama yang menyebabkan perlunya dilakukan penyesuaian tarif tiket KA kelas ekonomi diantaranya:

1. Fluktuasi harga bahan bakar minyak (BBM) bersubsidi.
2. Perubahan pedoman perhitungan tarif, dimana sebelumnya menggunakan PM No. 28 Tahun 2012 menjadi PM No. 69 Tahun 2014.
3. Perubahan margin dalam perhitungan biaya operasional KA ekonomi yang semula 8 persen menjadi 10 persen.
4. Fluktuasi kurs dolar Amerika Serikat terhadap mata uang rupiah.

Penyesuaian tarif pada layanan kereta api ekonomi jarak jauh mulai tahun 2014 sampai dengan tahun 2015 ditunjukkan oleh Tabel 2.1.

Tabel 2.1 Tarif Kereta Ekonomi yang disesuaikan

Kereta Api Ekonomi	Relasi	Jarak (km)	Tarif Tahun 2014 (Ribu)		Tarif Tahun 2015 (Ribu)		
			Apr- Des	Jan- Feb.	Mar	Apr	
Logawa	Purwokerto - Jember	668	50	115	50	80	
Kertajaya	Surabaya Pasarturi- Pasarsenen	716	50	135	50	90	
Brantas	Kediri- Pasarsenen	742	55	135	55	90	
Kahuripan	Kediri- Kiaracondong	636	50	125	50	90	
Kutojaya Utara	Kutoarjo- Pasarsenen	448	40	90	40	80	
Bengawan	Purwosari- Pasarsenen	568	50	110	50	80	
Progo	Lempuyangan -Pasarsenen	513	50	100	50	75	
Pasundan	Surabaya gubeng- Kiaracondong	691	55	130	55	100	
Sri Tanjung	Lempuyangan -Banyuwangi	612	50	110	50	100	
GBM Selatan	Surabaya gubeng- Pasarsenen	820	55	140	55	110	
Matarmaja	Malang- Pasarsenen	881	65	150	65	115	

Selain adanya penyesuaian tarif kereta api ekonomi, jumlah penumpang kereta api dapat pula dipengaruhi oleh karakteristik hari libur dan cuti bersama. Adapun menurut keputusan bersama pemerintah mengenai hari libur nasional dan cuti bersama pada tahun 2014 dengan surat keputusan No. 5 tahun 2013, No. 335 Tahun 2013, dan No. 05/SKB/MENPAN-RB/08/2013 selain itu pada tahun 2015 dengan surat keputusan No. 5 tahun 2014, No. 3/SKB/MEN/V/2014, dan No. 02/SKB/MENPAN/V/2014 ditun-

juukkan pada Tabel 2.2. Karakteristik hari selain hari libur dan cuti bersama juga dapat mempengaruhi jumlah penumpang misalnya penerimaan mahasiswa baru, libur akhir pekan, hari masuk kerja, dan lain sebagainya.

Tabel 2.2 Hari Libur Nasional dan Cuti Bersama
Tahun 2014 dan 2015

No	Libur Nasional	Tanggal	Hari
1	Tahun Baru	1 Januari 2014 1 Januari 2015	Rabu Kamis
2	Maulid Nabi Muhammad SAW	14 Januari 2014 3 Januari 2015	Selasa Sabtu
3	Tahun Baru Imlek	31 Januari 2014 19 Februari 2015	Jumat Kamis
4	Hari Raya Nyepi	31 Maret 2014 21 Maret 2015	Senin Sabtu
5	Wafat Isa Almasih	18 April 2014 3 April 2015	Jumat Jumat
6	Memperingati Hari Buruh Internasional	1 Mei 2014 1 Mei 2015	Kamis Jumat
7	Hari Raya Waisak	15 Mei 2014 14 Mei 2015	Kamis Kamis
8	Isra Mi'raj Nabi Muhammad SAW	27 Mei 2014 16 Mei 2015	Selasa Sabtu
9	Kenaikan Isa Isa Almasih	29 Mei 2014 2 Juni 2015	Kamis Selasa
10	Hari Raya Idul Fitri	28-29 Juli 2014 16-17 Juli 2015	Senin-Selasa Kamis-Jumat
11	Hari Kemerdekaan RI	17 Agustus 2014 17 Agustus 2015	Minggu
12	Hari Raya Idul Adha	5 Oktober 2014 24 September 2015	Senin Minggu
13	Tahun Baru Hijriyah	25 Oktober 2014 14 Oktober 2015	Kamis Sabtu
14	Hari Raya Natal	25 Desember 2014 24 Desember 2015	Rabu Kamis Kamis

No	Cuti Bersama	Tanggal	Hari
1	Hari Raya Idul Fitri	30-31 Juli dan 1 Agustus 2014 18-21 Juli 2015	Rabu-Jumat Sabtu-Selasa
2	Hari Raya Natal	26 Desember 2014 25 Desember 2015	Jumat Jumat

2.2 Time series

Time series atau deret waktu merupakan suatu rangkaian pengamatan yang didasarkan oleh urutan waktu pengamatan dengan interval waktu yang sama dimana setiap pengamatan tersebut berkorelasi. Suatu metodologi statistik yang dapat menganalisis suatu *time series* disebut sebagai analisis *time series*. Setiap pengamatan dinyatakan sebagai variabel random Z_t yang didapatkan berdasarkan indeks waktu tertentu t sebagai urutan waktu pengamatan dengan $t=1,2,3,\dots,n$ sehingga suatu *time series* yang dinyatakan sebagai suatu himpunan variabel random adalah $\{Z_1, Z_2, Z_3, \dots, Z_n\}$. Salah satu metode untuk analisis *time series* adalah prosedur Box-Jenkins (Wei, 2006).

2.3 Prosedur ARIMA Box-Jenkins

Analisis *time series* menggunakan prosedur ARIMA Box-Jenkins terdiri dari beberapa prosedur. Prosedur ARIMA Box-Jenkins dalam membangun suatu model terdiri dari identifikasi model, estimasi parameter, pemeriksaan diagnostik, dan pemilihan model terbaik. Berikut ini merupakan penjabaran prosedur ARIMA Box-Jenkins (Wei, 2006).

2.3.1 Identifikasi Model

Identifikasi model dilakukan untuk mengidentifikasi kebutuhan transformasi pada data yang belum stasioner dalam variansi, perbedaan pada data yang belum stasioner dalam rata-rata, dan menentukan orde p dan q yang tepat untuk model. Tahap-tahap dalam identifikasi model terdiri dari tiga tahapan berikut ini.

1. Membuat plot *time series* dan memilih transformasi yang tepat.

Plot *time series* digunakan untuk memeriksa plot apakah plot menunjukkan data yang memiliki tren, musiman, *outlier*, dan fenomena ketidakstasioneran data. Pada analisis *time series* dapat dilakukan proses transformasi untuk data yang tidak stasioner dalam variansi dan perbedaan untuk data yang tidak stasioner dalam rata-rata. Apabila data tidak stasioner dalam variansi dan rata-rata,

maka terlebih dahulu melakukan transformasi pada data karena transformasi tidak membutuhkan nilai yang negatif sedangkan proses pembedaan bisa jadi menghasilkan nilai yang negatif. Transformasi umum yang diperkenalkan oleh Box dan Cox untuk $\lambda \neq 0$ adalah sebagai berikut.

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.1)$$

Berikut ini merupakan beberapa nilai λ (lambda) yang umum digunakan dan transformasi yang dilakukan berdasarkan lambda.

Tabel 2.3 Nilai Lambda yang Umum digunakan dan Transformasi Terkait

Nilai λ	Transfomasi
-1,0	$\frac{1}{Z_t}$
-0,5	$\frac{1}{\sqrt{Z_t}}$
0,0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
-0,5	Z_t (tidak ada transfomasi)

Salah satu kelebihan dari digunakannya persamaan (2.1) adalah lambda dapat dijadikan sebagai parameter transformasi dan mengestimasi nilai.

2. Memeriksa sampel ACF dan PACF yang berasal dari data untuk mengonfirmasi orde yang tepat untuk pembedaan.

Korelasi antara variabel random Z_t dan Z_{t+k} disebut juga autokorelasi. *Autocorrelation function* (ACF) atau fungsi autokorelasi didefinisikan ρ_k sebagai fungsi dari k . Adapun suatu korelasi antara himpunan variabel random Z_t dan Z_{t+k} setelah ketergantungan linier terhadap variabel Z_{t+1}, Z_{t+2}, \dots , dan Z_{t+k-1} dihilangkan disebut juga sebagai parsial autokorelasi. *Partial autocorrelation function* (PACF) atau fungsi parsial autokorelasi ada-

lah ϕ_{kk} sebagai fungsi dari k . Time series $Z_1, Z_2, Z_3, \dots, Z_n$ memiliki sampel ACF yang dapat ditunjukkan oleh persamaan berikut ini.

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (2.2)$$

Berdasarkan persamaan dari (2.2) dikehui bahwa rata-rata sampel pengamatan adalah $\bar{Z} = \sum_{t=1}^n Z_t / n$. Suatu plot sampel ACF terhadap k dapat disebut juga sebagai sampel *correlogram*. Adapun sampel PACF dapat dihitung dari persamaan (2.3):

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.3)$$

Sampel ACF dan PACF yang digunakan minimal $n/4$ dengan n merupakan jumlah pengamatan dan minimum jumlah pengamatan untuk analisis *time series* adalah $n=50$. Beberapa kondisi dari ACF dan PACF dapat dijadikan aturan dalam menentukan proses pembedaan. Apabila ACF menurun atau merosot dengan lambat dan PACF putus setelah lag 1, maka hal hal tersebut mengindikasikan bahwa pembedaan diperlukan. Pada umumnya, pembedaan dilakukan $(1-B)^d Z_t$ dengan d dapat berupa 0,1, dan 2 dan dapat terjadi konsekuensi lebih serius apabila melakukan pembedaan yang tidak diperlukan.

3. Memeriksa sampel ACF dan PACF dari data yang telah stasioner.

Sampel ACF dan PACF dari data yang telah memenuhi stasioneritas dalam variansi dan rata-rata dapat digunakan untuk menentukan orde p dan q untuk model. Tabel 2.3 berikut ini menunjukkan karakteristik dari ACF dan PACF untuk data yang telah stasioner.

Tabel 2.4 Karakteristik Teoritis dari ACF dan PACF untuk Proses yang Stasioner

Proses	AR(p)	MA(q)	ARMA(p,q)
ACF	Turun cepat secara eksponensial/sinusoidal	Terputus setelah lag q	Turun cepat setelah lag ($q-p$)
PACF	Terputus setelah lag p	Turun cepat secara eksponensial/sinusoidal	Turun cepat setelah lag ($p-q$)

2.3.2 Estimasi Parameter

Salah satu metode untuk mengestimasi parameter dalam analisis *time series* adalah estimasi *Least Squares Estimation* atau estimasi kuadrat terkecil. Misalkan, persamaan umum dari AR(p) adalah sebagai berikut.

$$Z_t - \mu = \phi_1(Z_{t-1} - \mu) + \phi_2(Z_{t-2} - \mu) + \cdots + \phi_p(Z_{t-p} - \mu) + a_t \quad (2.4)$$

Model AR(p) tersebut dapat dilihat sebagai model regresi dengan $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$ sebagai variabel prediktor dan Z_t sebagai variabel respon. Metode *least square estimation* meminimumkan jumlah kuadrat error dari differensiasi:

$$Z_t - \mu - \phi_1(Z_{t-1} - \mu) - \phi_2(Z_{t-2} - \mu) - \cdots - \phi_p(Z_{t-p} - \mu) \quad (2.5)$$

Berdasarkan persamaan tersebut, diketahui bahwa $Z_1, Z_2, Z_3, \dots, Z_n$ diamati, maka proses penjumlahan dapat dilakukan menggunakan $t = p+1, p+2, p+3, \dots, n$. Sehingga metode estimasi *least square* meminimumkan persamaan berikut ini.

$$S_C(\phi_1, \phi_2, \dots, \phi_p, \mu) = \sum_{t=p+1}^n [(Z_t - \mu) - \phi_1(Z_{t-1} - \mu) - \cdots - \phi_p(Z_{t-p} - \mu)]^2 \quad (2.6)$$

Persamaan (2.6) disebut juga fungsi *conditional sum-of-squares*. Berdasarkan prinsip dari *least squares*, parameter ϕ dan μ diestimasi menggunakan masing-masing nilai yang meminimumkan

$S_c(\phi, \mu)$. Adapun persamaan (2.7) merupakan proses penurunan

$$\frac{\partial S_c}{\partial \mu} = 0 .$$

$$\sum_{t=p+1}^n 2[(Z_t - \mu) - \phi_1(Z_{t-1} - \mu) - \cdots - \phi_p(Z_{t-p} - \mu)](-1 + \phi_1 + \cdots + \phi_p) = 0 \quad (2.7)$$

Hasil penurunan yang ditunjukkan oleh persamaan (2.7) memberikan nilai estimasi parameter μ dari model AR(p) sedemikian hingga nilai estimasi seperti yang ditunjukkan oleh persamaan (2.8) berikut ini:

$$\mu = \frac{1}{(n-p)(1-\phi_1-\phi_2-\cdots-\phi_p)} \left[\sum_{t=p+1}^n Z_t - \phi_1 \sum_{t=p+1}^n Z_{t-1} - \cdots - \phi_p \sum_{t=p+1}^n Z_{t-p} \right] \quad (2.8)$$

untuk n berukuran besar diketahui bahwa:

$$\frac{1}{n-p} \sum_{t=p+1}^n Z_t \approx \frac{1}{n-p} \sum_{t=p+1}^n Z_{t-1} \approx \frac{1}{n-p} \sum_{t=p+1}^n Z_{t-2} \approx \cdots \approx \frac{1}{n-p} \sum_{t=p+1}^n Z_{t-p} \approx \bar{Z} \quad (2.9)$$

Berdasarkan persamaan (2.8) dapat diketahui bahwa nilai mendekati \bar{Z} sehingga persamaan (2.8) dapat disederhanakan menjadi:

$$\hat{\mu} \approx \frac{1}{1-\phi_1-\phi_2-\cdots-\phi_p} (\bar{Z} - \phi_1 \bar{Z} - \phi_2 \bar{Z} - \cdots - \phi_p \bar{Z}) = \bar{Z} \quad (2.10)$$

Selanjutnya, *least squares* meminimumkan $S_c(\phi_1, \phi_2, \dots, \phi_p)$ untuk mendapatkan estimasi parameter dari ϕ_i . Adapun estimasi parameter ϕ_i didapatkan dari $\frac{\partial S_c}{\partial \phi_i} = 0$ yang ditunjukkan oleh persamaan berikut ini.

$$\begin{aligned} \frac{\partial S_c}{\partial \phi_1} &= -2 \sum_{t=p+1}^n [(Z_t - \bar{Z}) - \phi_1(Z_{t-1} - \bar{Z}) - \cdots - \phi_p(Z_{t-p} - \bar{Z})] \\ &\quad (Z_{t-1} - \bar{Z}) = 0 \end{aligned} \quad (2.11)$$

Persamaan (2.11) dapat dituliskan kembali menjadi:

$$\sum_{t=p+1}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z}) = \left[\sum_{t=p+1}^n (Z_{t-1} - \bar{Z})^2 \right] \phi_1 + \left[\sum_{t=p+1}^n (Z_{t-1} - \bar{Z})(Z_{t-2} - \bar{Z}) \right] \phi_2 +$$

$$\cdots + \left| \sum_{t=p+1}^n (Z_t - \bar{Z})(Z_{t-p} - \bar{Z}) \right| \phi_p \quad (2.12)$$

Penjumlahan dari hasil lag $\sum_{t=p+1}^n (Z_t - \bar{Z})(Z_{t-p} - \bar{Z})$ mendekati nilai dari pembilang r_1 —namun tidak terdapat suatu hasil $(Z_p - \bar{Z})(Z_{p-1} - \bar{Z})$.

Kondisi yang sama terdapat pada $\sum_{t=p+1}^n (Z_{t-1} - \bar{Z})(Z_{t-p} - \bar{Z})$ yang tidak menyertakan suatu hasil $(Z_n - \bar{Z})(Z_{n-1} - \bar{Z})$. Apabila kedua ruas pada persamaan (2.12) dibagi dengan $\sum_{t=p+1}^n (Z_t - \bar{Z})^2$, maka hasil yang diperoleh adalah sebagai berikut.

$$r_1 = \phi_1 + r_1\phi_2 + r_2\phi_3 + \cdots + r_{p-1}\phi_p \quad (2.13)$$

Estimasi untuk parameter $\phi_2, \phi_3, \dots, \phi_p$ dapat dilakukan dengan cara yang sama sedemikian hingga hasil estimasi adalah dengan menyelesaikan persamaan berikut ini.

$$\left. \begin{array}{l} \phi_1 + r_1\phi_2 + r_2\phi_3 + \cdots + r_{p-1}\phi_p = r_1 \\ r_1\phi_1 + \phi_2 + r_1\phi_3 + \cdots + r_{p-2}\phi_p = r_2 \\ \vdots \\ r_{p-1}\phi_1 + r_{p-2}\phi_2 + r_{p-3}\phi_3 + \cdots + \phi_p = r_p \end{array} \right\} \quad (2.14)$$

Persamaan (2.14) dapat disebut juga persamaan Yule-Walker untuk model AR(p). Berdasarkan persamaan Yule-Walker r_k merupakan pengganti dari ρ_k , $k=1,2,\dots,p$ dengan ρ_k merupakan auto-korelasi lag ke- k .

Selanjutnya, model MA(q) dapat ditulis sebagai berikut ini.

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \cdots - \theta_q a_{t-q} \quad (2.15)$$

Penerapan metode *least squares* sulit dilakukan pada model MA(q) dalam persamaan (2.15) sehingga model MA(q) dapat diterjemahkan ke dalam model AR dengan orde tak hingga, namun permasalahan muncul karena representasi model AR orde tak hingga menghasilkan permasalahan nonlinier pada parameter. Ber-

dasarkan hal tersebut, maka persamaan (2.15) dapat ditulis kembali sebagai berikut ini.

$$a_t = Z_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \cdots + \theta_q a_{t-q} \quad (2.16)$$

Perhitungan a_t , $t=1,2,\dots,n$ dapat dilakukan dengan nilai awal $a_0 = a_{-1} = \cdots = a_{-q} = 0$. Kemudian, perhitungan dapat dilakukan pada $S_c(\theta_1, \theta_2, \dots, \theta_q) = \sum_1^n (e_t)^2$ untuk masing-masing parameter. Jumlah kuadrat diminimumkan pada $\theta_1, \theta_2, \dots, \theta_p$ menggunakan metode numerik multivariat.

Selain itu estimasi parameter untuk model ARMA (p,q) dapat dilakukan. Adapun model ARMA (p,q) dapat dituliskan sebagai berikut ini.

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \cdots + \phi_p Z_{t-p} - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \cdots - \theta_q a_{t-q} + a_t \quad (2.17)$$

Penulisan kembali persamaan (2.17) dapat ditunjukkan sebagai berikut ini.

$$a_t = Z_t - \phi_1 Z_{t-1} - \phi_2 Z_{t-2} - \cdots - \phi_p Z_{t-p} + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \cdots + \theta_q a_{t-q} \quad (2.18)$$

Persamaan (2.18) menghitung a_t dengan $a_p = a_{p-1} = \cdots = a_{p+1-q} = 0$. Selanjutnya, estimasi *conditional least squares* dihitung dengan meminimumkan $S_c(\phi_1, \phi_2, \dots, \phi_p, \theta_1, \theta_2, \dots, \theta_q)$.

Estimasi parameter yang telah diperoleh dapat dilakukan pengujian signifikansi parameter. Adapun hipotesis dan statistik uji yang digunakan untuk setiap parameter dari AR(p) dan MA(q) adalah sebagai berikut.

Tabel 2.5 Hipotesis dan Statistik Uji untuk Signifikansi Parameter

Hipotesis	
AR(p)	MA(q)
$H_0: \phi_i = 0$	$H_0: \theta_j = 0$
$H_1: \phi_i \neq 0$, $i = 1, 2, \dots, p$	$H_1: \theta_j \neq 0$, $j = 1, 2, \dots, q$

Tabel 2.5 Hipotesis dan Statistik Uji untuk Signifikansi Parameter (Lanjutam)

		Statistik Uji	
AR(p)		MA(q)	
$t_{hitung} = \frac{\hat{\phi}_i}{s.e.(\hat{\phi}_i)}$	(2.19)	$t_{hitung} = \frac{\hat{\theta}_j}{s.e.(\hat{\theta}_j)}$	(2.20)

H_0 ditolak apabila $|t_{hitung}| \geq t_{\frac{\alpha}{2}, n-p}$, dengan n menunjukkan banyaknya data dan p menunjukkan banyak parameter pada model (Cryer & Chan, 2008).

2.3.3 Pemeriksaan Diagnostik

Pemeriksaan diagnostik dilakukan setelah ditemukan parameter yang signifikan terhadap model. Adapun pemeriksaan ini dilakukan terhadap residual yang merupakan hasil dari estimasi parameter. Pemeriksaan diagnostik meliputi pengujian asumsi distribusi normal dan *white noise* terhadap residual (Wei, 2006).

Pengujian asumsi distribusi normal digunakan untuk mengetahui apakah residual berdistribusi normal atau tidak. Uji *Kolmogorov-Smirnov* merupakan salah satu pengujian yang dapat dilakukan dalam pengujian asumsi distribusi normal. Berikut ini merupakan hipotesis yang digunakan.

H_0 : Data mengikuti distribusi normal

H_1 : Data tidak mengikuti distribusi normal

Statistik uji yang diperkenalkan oleh Kolmogorov adalah sebagai berikut ini:

$$D = \max \{D^+, D^-\} \quad (2.21)$$

dengan $D^+ = \max_i \{i/n - Z_{(i)}\}$, $D^- = \max_i \{Z_{(i)} - (i-1)/n\}$, serta $Z_{(i)} = F(x_{(i)})$. Adapun $F(x)$ adalah fungsi distribusi peluang dari distribusi normal dan $x_{(i)}$ merupakan orde statistik ke- h dari sampel random dengan $1 \leq i \leq n$ dan n merupakan ukuran sampel. Hi-

potesis nol ditolak apabila $D > D_{(1-\alpha;n)}$ dengan $D_{(1-\alpha;n)}$ merupakan nilai pada tabel *Kolmogorov-Smirnov* (Stephen, 1993).

Asumsi bahwa residual *white noise* dapat diartikan sebagai $\{\epsilon_t\}$ merupakan himpunan variabel random yang tidak berkorelasi dengan rata-rata adalah nol dan variansi yang konstan. Pengujian asumsi *white noise* digunakan untuk mengetahui apakah residual *white noise*. Salah satu pengujian yang digunakan adalah uji *portmanteau lack of fit*. Pengujian tersebut menggunakan sampel fungsi autokorelasi dari residual untuk hipotesis, yaitu sebagai berikut ini:

$$H_0: \rho_k = 0 \quad \forall k$$

$$H_1: \rho_k \neq 0 \quad \exists k, k=1,2,\dots,K$$

Adapun statistik uji yang digunakan adalah :

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.22)$$

dengan n merupakan ukuran sampel dan $\hat{\rho}_k$ menunjukkan autokorelasi residual pada lag ke- k . Hipotesis nol ditolak apabila $Q > X_{(1-\alpha), df=K-m}^2$ dengan $m=p+q$ (Wei, 2006).

2.3.4 Pemilihan Model Terbaik

Analisis *time series* memungkinkan untuk dapat memberikan beberapa model yang memiliki parameter signifikan dan menuhi asumsi. Apabila tujuan pemodelan adalah untuk meramalkan nilai periode mendatang, maka alternatif kriteria pemilihan model berdasarkan kesalahan peramalan. Berikut ini kriteria berdasarkan kesalahan peramalan *out sample* (Wei, 2006).

$$\text{MAPE} = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \right) \times 100\% \quad (2.23)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2} \quad (2.24)$$

MAPE merupakan *Mean Absolute Percentage Error* sedangkan RMSE adalah *Root Mean Square Error*. Berdasarkan

persamaan tersebut, n merupakan banyaknya *out sample*, Z_t merupakan data aktual ke- t dan \hat{Z}_t merupakan peramalan ke- t dari *out sample*. MAPE merupakan ukuran relatif yang mengekspresikan suatu error sebagai persentase dari data asli sehingga kelebihan MAPE adalah MAPE menyediakan suatu cara yang mudah untuk menilai sejauh mana error yang dihasilkan peramalan. RMSE berguna apabila terdapat suatu error besar yang memiliki proporsi jauh lebih besar daripada yang error yang lebih kecil namun setara (misalnya error sebesar 100 dibanding dua error masing-masing sebesar 50) (Makridakis & Hibon, 1995).

2.4 Model ARIMA (p,d,q) $(P,D,Q)^s$ Musiman Multiplikatif

Suatu variabel random Z_t dapat memiliki hubungan yang terdiri dari hubungan di dalam periode (nonmusiman) maupun hubungan antar periode (musiman). Hubungan yang terjadi di dalam periode merepresentasikan korelasi di antara $\dots Z_{t-2}, Z_{t-1}, Z_t, Z_{t+1}, Z_{t+2}, \dots$ sedangkan hubungan antar periode merepresentasikan korelasi antara $\dots Z_{t-2s}, Z_{t-s}, Z_t, Z_{t+s}, Z_{t+2s}, \dots$. Model ARIMA (p,d,q) dapat ditunjukkan sebagai berikut ini.

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t \quad (2.25)$$

Apabila variabel random Z_t tidak diketahui terdiri dari hubungan antar periode (musiman), maka model ARIMA (p,d,q) dapat didefinisikan sebagai berikut.

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)b_t \quad (2.26)$$

Sehingga berdasarkan persamaan (2.26), suatu rangkaian himpunan variabel random $\{b_t\}$ bisa dikatakan bukan proses *white noise* apabila terdiri dari sesuatu yang belum dapat dijelaskan dari korelasi antar periode (musiman). Model yang merepresentasikan hubungan yang terjadi antar periode adalah model ARIMA $(P,D,Q)^s$ musiman yang dapat didefinisikan berikut ini.

$$\Phi_P(B^s)(1-B^s)^D b_t = \Theta_Q(B^s)a_t \quad (2.27)$$

Adapun penggabungan antara persamaan (2.26) dan (2.27) dapat menghasilkan model ARIMA $(p,d,q)(P,D,Q)^s$ musiman multiplikatif Box-Jenkins. Model ARIMA $(p,d,q)(P,D,Q)^s$ musiman multiplikatif Box-Jenkins didefinisikan berikut ini.

$$\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D Z_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (2.28)$$

Berdasarkan persamaan (2.25), (2.26), dan (2.27), dapat dijelaskan definisi dari masing-masing operator untuk setiap persamaan tersebut berikut ini.

- $\phi_p(B)$:operator AR dengan $\phi_p(B) = (1 - \phi_1 B^1 - \phi_2 B^2 - \dots - \phi_p B^p)$
- $\theta_q(B)$:operator MA dengan $\theta_q(B) = (1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q)$
- $(1-B)^d$:operator untuk pembedaan orde d
- $\Phi_P(B^s)$:operator AR musiman orde s dan diketahui bahwa $\Phi_P(B) = (1 - \Phi_1 B^1 - \Phi_2 B^2 - \dots - \Phi_p B^p)$
- $\Theta_Q(B^s)$:operator MA musiman orde s dan diketahui bahwa $\Theta_Q(B) = (1 - \Theta_1 B^1 - \Theta_2 B^2 - \dots - \Theta_q B^q)$
- $\{Z_t\}$:serangkaian variabel random dengan proses yang stasioner dengan $t=1,2,\dots,n$
- $\{a_t\}$:serangkaian variabel random yang tidak berkorelasi dengan rata-rata yang konstan $E(a_t) = \mu_a$ biasanya diasumsikan bernilai nol, memiliki variansi yang konstan yaitu $\text{Var}(a_t) = \sigma_a^2$, serta $\gamma_k = \text{Cov}(a_t, a_{t+k}) = 0, k \neq 0$
- $\{b_t\}$:serangkaian variabel random yang mengandung korelasi antar periode yang belum dijelaskan.

2.5 Deteksi *Outlier*

Outlier merupakan suatu pengamatan yang tidak konsisten terhadap serangkaian pengamatan dan penyebab terjadinya *outlier* biasanya tidak diketahui. *Outlier* dapat membuat kesimpulan yang dihasilkan dari analisis data menjadi tidak valid. Oleh karena

itu prosedur untuk mendeteksi dan menghapus efek *outlier* menjadi penting. Adapun model statistik yang mampu mendeteksi *outlier* dalam *time series* adalah *additive outlier* dan *innovational outlier* (Wei, 2006).

Apabila Z_t merupakan serangkaian pengamatan dan X_t merupakan serangkaian pengamatan yang bebas dari *outlier*, maka diasumsikan $\{X_t\}$ mengikuti model ARMA(p,q) berikut ini.

$$\phi(B)X_t = \theta(B)a_t \quad (2.29)$$

Berdasarkan persamaan tersebut $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ dan $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ adalah stasioner dan invertibel serta $\{a_t\}$ adalah *white noise* dan berdistribusi $N(0, \sigma_a^2)$. Adapun model *additive outlier* (AO) adalah sebagai berikut.

$$Z_t = \begin{cases} X_t, & t \neq T \\ X_t + \omega, & t = T \end{cases} \quad (2.30)$$

$$\begin{aligned} Z_t &= X_t + \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} \alpha_t + I_t^{(T)} \end{aligned} \quad (2.31)$$

dengan

$$I_t^{(T)} = \begin{cases} 0 & t \neq T \\ 1 & t = T \end{cases} \quad (2.32)$$

Berdasarkan persamaan tersebut, diketahui bahwa $I_t^{(T)}$ bernilai 1 apabila *outlier* terjadi pada periode ke- T dan bernilai nol apabila tidak terdapat *outlier* pada periode ke- T dengan T merupakan waktu yang tidak diketahui dari terjadinya *outlier* yang mungkin sedangkan ω merupakan parameter *outlier*. *Additive outlier* berpengaruh pada pengamatan ke- T saja yaitu Z_T .

Berbeda dengan *additive outlier*, *Innovational outlier* berpengaruh pada seluruh pengamatan Z_T, Z_{T+1}, \dots mulai dari periode ke- T hingga sistem yang dideskripsikan oleh $\theta(B)/\phi(B)$ kemudi-

an kembali ke pola semula, hal tersebut ditunjukkan oleh persamaan (2.33). Berikut ini merupakan model *Innovational Outlier* (IO).

$$\begin{aligned} Z_t &= X_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} (\alpha_t + \omega I_t^{(T)}) \end{aligned} \quad (2.33)$$

Selain *additive* dan *innovational outlier*, adapula *level shift* (LS) dan *temporary change* (TC) yang dapat menjadi prosedur deteksi *outlier* sehingga terdapat empat tipe *outlier* yang dapat diketahui (Wei, 2006). *Level shift* menunjukkan *outlier* yang terjadi mempengaruhi pengamatan Z_T, Z_{T+1}, \dots dan membentuk pola baru yang berbeda dari pengamatan sebelumnya dan permanen, hal tersebut ditunjukkan oleh persamaan (2.34) dan (2.35) berikut ini.

$$\begin{aligned} Z_t &= X_t + \frac{1}{(1-B)} \omega_L I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} \alpha_t + \frac{1}{(1-B)} \omega_L I_t^{(T)} \end{aligned} \quad (2.34)$$

atau dapat dituliskan sebagai berikut:

$$Z_t = \frac{\theta(B)}{\phi(B)} \alpha_t + \omega_L S_t^{(T)} \quad (2.35)$$

dengan

$$S_t^{(T)} = \begin{cases} 0, & t \geq T \\ 1, & t < T \end{cases} \quad (2.36)$$

Model *level shift* pada persamaan (2.34) dan (2.35) menunjukkan bahwa ω_L merupakan parameter *outlier* model *level shift*.

Deteksi *outlier temporary change* mendeteksi suatu *outlier* yang terjadi pada waktu t dan pengaruhnya berangsur-angsur menghilang secara lambat dan cenderung kembali ke pola semula seiring dengan berkurangnya nilai faktor δ , hal tersebut berdasarkan persamaan (2.37).

$$\begin{aligned}
 Z_t &= X_t + \frac{1}{(1-\delta B)} \omega_c I_t^{(T)} \\
 &= \frac{\theta(B)}{\phi(B)} \alpha_t + \frac{1}{(1-\delta B)} \omega_c I_t^{(T)}
 \end{aligned} \tag{2.37}$$

Persamaan (2.37) menunjukkan bahwa ω_c merupakan parameter *outlier* model *temporary change* dan diketahui bahwa $0 \leq \delta \leq 1$. Apabila $\delta = 1$ maka pengaruh *outlier* secara linier meningkat.

2.6 Pengujian Linieritas

Pengujian linieritas untuk *time series* pada penelitian ini difokuskan pada satu variabel dependen yaitu Z_t . Adapun suatu informasi dari w_t yang menyatakan variabel lag Z_t dan suatu vektor dari variabel eksogen dapat digunakan suntuk uji linieritas Z_t . Pengujian linieritas yang diperkenalkan berdasarkan konsep *neural network* atau jaringan syaraf tiruan ini oleh White (1989) dan Lee dkk. (1993) merupakan suatu uji untuk linieritas melawan persamaan nonlinier di bawah ini.

$$Z_t = \beta' w_t + \sum_{j=1}^q \theta_{0j} \left\{ \psi(\gamma_j' w_t) + \frac{1}{2} \right\} + a_t \tag{2.38}$$

dengan $\beta = (\beta_0, \beta_1, \dots, \beta_p)', w_t = (1, \tilde{w}'_t)', \tilde{w}'_t = (Z_{t-1}, \dots, Z_{t-p})'$, $a_t \sim \text{nid}(0, \sigma^2)$. Selain itu, $\psi(\gamma_j' w_t) = \{1 + \exp(-\gamma_j' w_t)\}^{-1} - \frac{1}{2}$ dengan q adalah banyaknya unit neuron pada lapis tersembunyi.

Adapun uji hipotesis menyatakan bahwa Z_t linier yaitu $Z_t = \beta' w_t + a_t$ sehingga hipotesis yang digunakan adalah sebagai berikut:

$$H_0: \theta_{0j} = 0, \forall j$$

$$H_1: \exists j, \theta_{0j} \neq 0, j = 1, 2, \dots, q$$

dengan θ_{0j} merupakan bobot-bobot yang diproses bersama *output* dari lapisan tersembunyi pada fungsi linier di lapisan *output*.

Uji linieritas termasuk ke dalam implementasi tipe lagrange multiplifier (LM) yang diperkenalkan oleh Lee dkk. (1993) dan Terasvirta dkk. (1993) menggunakan salah satunya adalah statistik uji χ^2 sebagai berikut ini:

$$\chi^2 = nR^2 \quad (2.39)$$

dengan n merupakan banyak sampel yang digunakan dan R^2 merupakan koefisien determinasi dari hasil regresi. Langkah-langkah dalam uji linieritas tersebut adalah sebagai berikut.

1. Meregresikan y_t dengan 1 dan $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$ kemudian menghitung residual $\hat{u}_t = Z_t - \hat{Z}_t$. Diketahui bahwa p merupakan lag yang digunakan. Namun dalam hal ini lag yang digunakan hanya Z_{t-1} sesuai dengan *default* paket R *software* yang digunakan.
2. Meregresikan \hat{u}_t dengan 1, Z_{t-1} serta sebanyak m prediktor tambahan kemudian menghitung koefisien determinasi dari hasil regresi yaitu R^2 . Dalam hal ini, pada uji Terasvirta dkk. (1993) m prediktor tambahan adalah suku kuadratik dan kubik yang merupakan hasil dari pendekatan ekspansi Taylor.
3. Menghitung statistik uji χ^2 .

Adapun statistik uji χ^2 mendekati distribusi $\chi^2(m)$, dengan m merupakan banyak prediktor tambahan (Suhartono, 2007). Berdasarkan uji hipotesis, hipotesis nol ditolak apabila ditemukan kondisi $\chi^2 > \chi^2(m)$.

2.7 Soft Computing

Soft computing pada umumnya tidak melakukan banyak manipulasi simbolik, sehingga *soft computing* dapat didefinisikan sebagai disiplin baru yang melengkapi pendekatan kecerdasan buatan (*artificial intelligence/ AI*) konvensional dan sebaliknya. Beberapa kerangka bernalar yang membangun suatu *soft computing* adalah *neural network* atau jaringan syaraf tiruan dan sistem

fuzzy. Komponen-komponen tersebut memiliki kelebihan masing-masing. Kelebihan dari *neural network* adalah melakukan pembelajaran dan adaptasi. *Neural Network* memproses suatu informasi dengan merepresentasikan otak manusia. Aturan *if-then* dari sistem fuzzy membentuk suatu komponen kunci dari *fuzzy inference system* (FIS) yang dapat secara efektif memodelkan keahlian manusia dalam aplikasi yang spesifik, Namun sistem fuzzy tidak memiliki suatu kemampuan adaptasi untuk menangani perubahan lingkungan. Maka, penggabungan kedua kerangka bernalar *soft computing* yaitu konsep pembelajaran *neural network* pada *fuzzy inference systems* menghasilkan pemodelan neuro-fuzzy yang merupakan teknik penting dalam *soft computing*. Salah satu pemodelan neuro-fuzzy adalah model *Adaptive Neuro Fuzzy Inference Systems* atau dapat disebut ANFIS (Jang , Sun, & Mizutani, 1997).

2.7.1 Teori Himpunan Fuzzy

Teori himpunan fuzzy pertama kali diperkenalkan oleh Zadeh (1965) yang menyebutkan bahwa himpunan fuzzy merupakan suatu kelas objek dengan rangkaian nilai keanggotaan. Himpunan tersebut ditandai dengan fungsi keanggotaan yang memberikan nilai keanggotaan pada setiap objek dengan rentang nilai antara nol dan satu. Himpunan fuzzy berbeda dengan himpunan klasik yang memberikan hanya dua kemungkinan nilai keanggotaan yaitu satu untuk menjadi anggota himpunan dan nol untuk bukan menjadi anggota himpunan. Beberapa fungsi keanggotaan yang dapat digunakan adalah fungsi keanggotaan bentuk kurva *trapezoidal*, *Gaussian*, *Generalized Bell*, *Triangular*, dan *Pi*. Berikut ini merupakan penjelasan mengenai beberapa fungsi keanggotaan satu dimensi yang menggunakan *single input* yang digunakan dalam penelitian ini (Jang , Sun, & Mizutani, 1997).

1. Fungsi Keanggotaan Trapezoidal

Fungsi keanggotaan trapezoidal yang memiliki empat parameter yaitu $\{a, b, c, d\}$ ditunjukkan sebagai berikut.

$$\text{trap}(Z; a, b, c, d) = \begin{cases} 0, & Z \leq a \\ (Z - a)/(b - a), & a \leq Z \leq b \\ 1, & b \leq Z \leq c \\ (d - Z)/(d - c), & c \leq Z \leq d \\ 0, & d \leq Z \end{cases} \quad (2.40)$$

Selain fungsi yang ditunjukkan pada persamaan (2.40), fungsi keanggotaan trapezoidal dapat pula didefinisikan sebagai fungsi berikut ini.

$$\text{trap}(Z; a, b, c, d) = \max \left(\min \left(\frac{(Z - a)}{(b - a)}, 1, \frac{(d - Z)}{(d - c)} \right), 0 \right) \quad (2.41)$$

2. Fungsi Keanggotaan Gaussian

Parameter yang menentukan fungsi keanggotaan Gaussian adalah $\{c, \sigma\}$. Berikut ini merupakan fungsi keanggotaan *Gaussian*.

$$\text{gauss}(Z, c, \sigma) = e^{-\frac{1}{2}\left(\frac{Z-c}{\sigma}\right)^2} \quad . \quad (2.42)$$

Persamaan tersebut menunjukkan bahwa c merepresentasikan nilai rata-rata dari fungsi keanggotaan dan σ menunjukkan lebar dari fungsi keanggotaan.

3. Fungsi Keanggotaan Generalized Bell

Fungsi keanggotaan generalized bell memiliki tiga parameter $\{a, b, c\}$. Fungsi keanggotaan *generalized bell* ditunjukkan oleh persamaan berikut ini.

$$\text{gbell}(Z; a, b, c) = \frac{1}{1 + \left| \frac{Z-c}{a} \right|^{2b}} \quad (2.43)$$

Parameter b pada fungsi keanggotaan generalized bell selalu bernilai positif.

4. Fungsi Keanggotaan Triangular

Fungsi keanggotaan triangular ditentukan oleh tiga parameter yaitu. Fungsi keanggotaan triangular ditunjukkan sebagai berikut ini.

$$tri(Z; a, b, c) = \begin{cases} 0, & Z \leq a \\ (Z-a)/(b-a), & a \leq Z \leq b \\ (c-Z)/(c-b), & b \leq Z \leq c \\ 0, & c \leq Z \end{cases} \quad (2.44)$$

Fungsi keanggotaan triangular juga dapat menggunakan cara berikut ini.

$$tri(Z; a, b, c) = \max \left(\min \left(\frac{(Z-a)}{(b-a)}, \frac{(c-Z)}{(c-b)} \right), 0 \right) \quad (2.45)$$

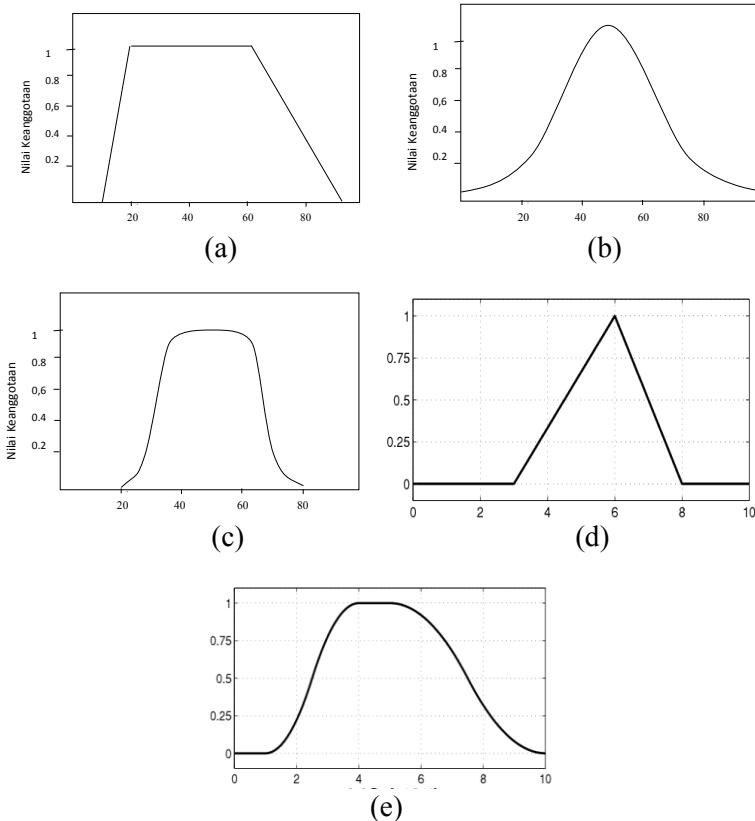
5. Fungsi Keanggotaan *Pi*

Fungsi keanggotaan triangular ditentukan oleh empat parameter yaitu $\{a, b, c, d\}$. Fungsi keanggotaan triangular ditunjukkan sebagai berikut ini.

$$pi(Z; a, b, c, d) = \begin{cases} 0, & Z \leq a \\ 2((Z-a)/(b-a))^2, & a \leq Z \leq (a+b)/2 \\ 1-2((Z-b)/(b-a))^2, & (a+b)/2 \leq Z \leq b \\ 1-2((Z-c)/(d-c))^2, & c \leq Z \leq (c+d)/2 \\ 2((Z-d)/(d-c))^2 & (c+d)/2 \leq Z \leq d \\ 0 & Z \geq d \end{cases} \quad (2.46)$$

Fungsi keanggotaan pada kelima jenis fungsi keanggotaan memiliki jumlah parameter yang berbeda-beda yaitu fungsi keanggotaan *Gaussian* memiliki dua parameter, fungsi keanggotaan *triangular* dan *Generalized Bell* memiliki tiga parameter, dan fungsi keanggotaan *trapezoidal* dan *Pi* memiliki empat parameter. Parameter-parameter tersebut yang dapat menentukan bentuk kurva

dari fungsi keanggotaan yang ditunjukkan oleh Gambar 2.1 berikut ini.



Gambar 2.1 Bentuk Fungsi Keanggotaan (a) $\text{trap}(Z; 10,20,60,95)$; (b) $\text{gauss}(Z; 50,20)$; (c) $\text{Gbell}(Z;20;4;50)$; (d) $\text{Tri}(Z; 3,6,8)$ (e) $\text{Pi}(Z;1 4 5 10)$

2.7.2 Model *Adaptive Neuro Fuzzy Inference Systems* (ANFIS)

Adaptive-Network-Based Fuzzy Inference System atau dikenal sebagai *Adaptive Neuro Fuzzy Inference Systems* (ANFIS) merupakan *fuzzy inference system* yang diimplementasikan pada susunan *adaptive networks*. ANFIS pertama kali diperkenalkan o-

leh Jang (1993) dengan mensimulasikan arsitektur ANFIS. Adapun arsitektur ANFIS diterapkan untuk memodelkan fungsi nonlinier serta membandingkannya dengan pendekatan *neural network*, mengidentifikasi serangkaian komponen nonlinier pada sistem kendali dan meramalkan *chaotic time series* serta membandingkannya dengan metode statistik konvensional dan metode yang berkaitan lainnya. Salah satu simulasi yang dilakukan adalah melakukan peramalan terhadap *chaotic time series* dan membandingkannya dengan metode statistik/ model linier yaitu model *Autoregressive* (AR). Adapun *input* ANFIS dibangun dari empat parameter pada model AR yang digunakan dan dua fungsi keanggotaan sehingga aturan *if-then* adalah sejumlah 16. Hasil simulasi dibandingkan menggunakan non-dimensional error index (NDEI) yang diperoleh dari RMSE dibagi dibandingkan dengan standar deviasi dari *target series*. Adapun ANFIS memiliki NDEI yang paling kecil yaitu sebesar 0.007 dibandingkan dengan model AR dengan NDEI sebesar 0.19. Secara umum dapat disimpulkan bahwa ANFIS memiliki pencapaian yang lebih unggul dibandingkan dengan metode linier yang umum digunakan untuk menganalisis *time series* yang nonlinier.

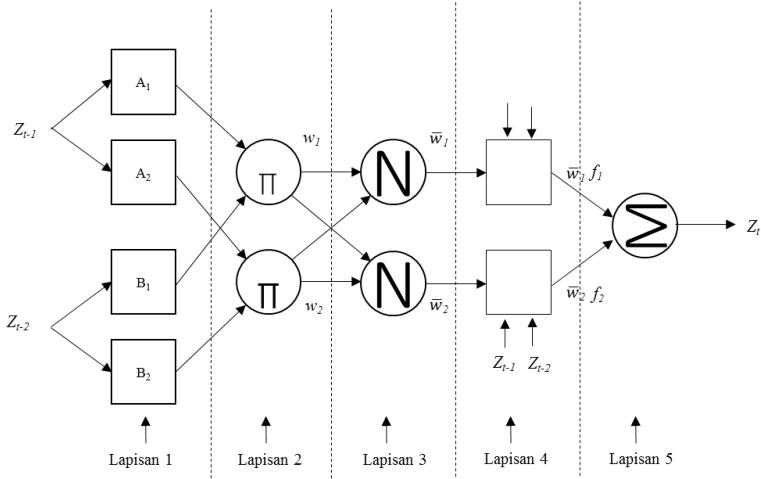
Arsitektur ANFIS dapat dijelaskan dengan mengasumsikan bahwa *fuzzy inference system* memiliki dua *input* yaitu Z_{t-1} dan Z_{t-2} dan satu *output* Z_t . Arsitektur ANFIS yang digunakan dalam hal ini adalah arsitektur ANFIS Sugeno. Adapun arsitektur ANFIS yang digunakan dalam penelitian ini berdasarkan dua aturan *fuzzy if-then* tipe Takagi dan Sugeno, dengan memisalkan *input* Z_{t-1} dan Z_{t-2} , maka: (Sugeno & Kang, 1988; Takagi & Sugeno, 1983; Takagi & Sugeno, 1985).

if Z_{t-1} adalah A_1 **and** Z_{t-2} adalah B_1 , *then* $f_1 = p_1 Z_{t-1} + q_1 Z_{t-2} + r_1$

if Z_{t-1} adalah A_1 **and** Z_{t-2} adalah B_2 , *then* $f_2 = p_2 Z_{t-1} + q_2 Z_{t-2} + r_2$

Arsitektur ANFIS memiliki lima lapisan. Setiap lapisan memiliki node-node yang melakukan fungsi yang sama. Node tersebut dapat berupa node adaptif yang ditunjukkan oleh bentuk node kotak dan berupa node tetap yang ditunjukkan oleh node bentuk lingkaran.

Adapun arsitektur ANFIS yang setara dapat ditunjukkan oleh Gambar 2.2.



Gambar 2.2. Arsitektur ANFIS yang Setara

Adapun arsitektur ANFIS setara yang ditunjukkan oleh Gambar 2.2 memiliki lima lapisan yang memproses suatu *input*, antara lain:

1. Lapisan 1

Setiap node i pada lapisan 1 ini merupakan node adaptif dengan fungsi node sebagai berikut:

$$O_{1,i} = \mu A_i(Z_{t-1}), \text{ untuk } i=1,2 \text{ atau} \quad (2.47)$$

$$O_{1,i} = \mu B_{i-2}(Z_{t-2}), \text{ untuk } i=3,4$$

Berdasarkan fungsi tersebut, Z_{t-1} (atau Z_{t-2}) merupakan *input* ke node I dan A_i (atau B_{i-2}) merupakan label linguistik yang berhubungan dengan node tersebut, sehingga μA_i merupakan nilai keanggotaan dari himpunan fuzzy A_i . Fungsi keanggotaan A_i dapat berupa fungsi keanggotaan parameter yang sesuai, misalnya fungsi keanggotaan *generalized bell* pada persamaan (2.48) ini.

$$\mu_A(Z_{t-1}) = \frac{1}{1 + \left| \frac{Z_{t-1} - c_i}{a_i} \right|^{2b}} \quad (2.48)$$

dengan $\{a_i, b_i, c_i\}$ adalah himpunan parameter dan parameter yang terdapat lapisan 1 dikenal dengan nama *premise parameters*. Parameter tersebut merupakan hasil

2. Lapisan 2

Setiap node pada lapisan 2 merupakan node tetap yang berlabel Π yang memiliki *output* berupa hasil dari sinyal masuk berikut ini.

$$O_{2,i} = w_i = \mu_{A_i}(Z_{t-1}) \mu_{B_i}(Z_{t-2}) \text{ untuk } i=1,2 \quad (2.49)$$

Setiap node merepresentasikan w_i sebagai *the firing strength of the rule* yaitu suatu nilai keanggotaan sebagai hasil dari operasi dua himpunan.

3. Lapisan 3

Setiap node pada lapisan 3 merupakan node tetap yang berlabel N. Node ke- i menghitung rasio ke- i dari *rule's firing strength* terhadap jumlah keseluruhan *rule's firing strengths* seperti yang ditunjukkan fungsi berikut ini.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \text{ untuk } i=1,2 \quad (2.50)$$

Output dari lapisan 3 yaitu \bar{w}_i atau disebut juga sebagai *normalized firing strengths*.

4. Lapisan 4

Lapisan 4 terdiri dari setiap node i yang merupakan node adaptif dengan suatu fungsi node sebagai berikut:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i Z_{t-1} + q_i Z_{t-2} + r_i) \quad (2.51)$$

Berdasarkan fungsi node tersebut, diketahui \bar{w}_i merupakan *normalized firing strengths* dari lapisan 3 dan f_i merupakan hasil operasi parameter dalam node ini. Dalam hal ini, para-

meter $\{p_i, q_i, r_i\}$ merupakan parameter pada lapisan 4 yang disebut juga *consequent parameters*.

5. Lapisan 5

Node tunggal pada lapisan 5 merupakan node tetap yang berlabel Σ . Node tersebut menghitung jumlah keseluruhan *output* sebagai hasil terakhir dari seluruh sinyal masuk. Adapun *output* keseluruhan dapat ditunjukkan oleh persamaan berikut ini.

$$O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (2.52)$$

Alur maju pada algoritma pembelajaran hybrid menunjukkan *output* dari suatu *node* akan berjalan maju sampai lapisan ke-4 dan *consequent parameters* diidentifikasi oleh metode *least squares*. Sedangkan pada alur mundur, sinyal error akan merambat secara mundur dan *premise parameters* diperbaharui oleh *gradient descent*.

Halaman ini sengaja dikosongkan

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari PT. KAI DAOP VIII Stasiun Pasar Turi, Surabaya. Adapun data yang digunakan adalah data jumlah penumpang Kereta Api Kelas Ekonomi Kertajaya mulai 1 Mei 2014 sampai dengan 6 Mei 2015 sehingga data yang digunakan sebanyak 371 data. Variabel yang digunakan dalam penelitian ini adalah data jumlah penumpang harian Kereta Api Kertajaya.

3.2 Langkah-langkah Analisis

Langkah-langkah yang dilakukan dalam penelitian dapat dibagi menjadi tiga macam yaitu langkah-langkah dalam analisis pemodelan ARIMA Box Jenkins, pengujian linieritas, dan pemodelan ANFIS. Berikut ini dijelaskan langkah analisis menggunakan ARIMA Box Jenkins.

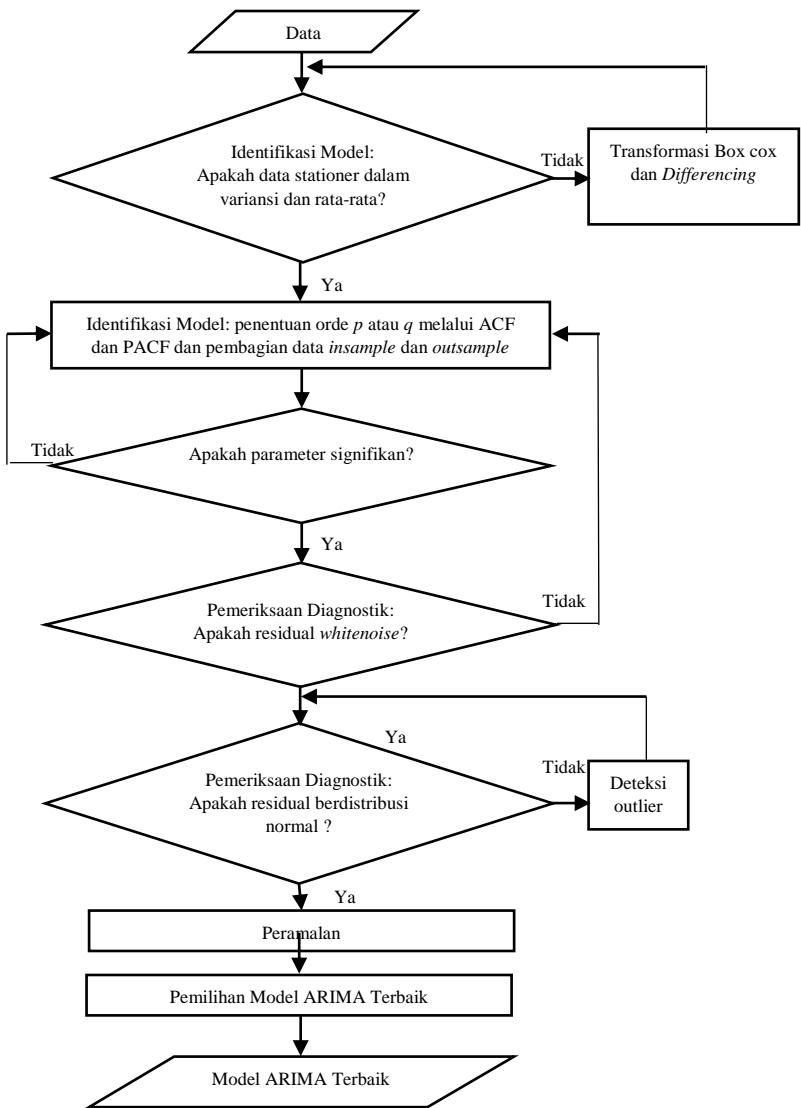
1. Melakukan identifikasi model. Adapun hal yang harus dilakukan adalah membuat plot *time series* untuk mengetahui karakteristik data secara visual kestasioneran data, apabila data tidak stasioner dalam variansi maka perlu dilakukan transformasi Box-cox. Setelah itu memeriksa ACF dan PACF terkait kebutuhan *differencing* untuk menstasionerkan data dalam rata-rata. Setelah itu membuat plot ACF dan PACF dari data yang telah stasioner untuk mengetahui orde p dan q dari model. Setelah mengetahui karakteristik data, maka data jumlah penumpang harian Kereta Api Kertajaya dibagi menjadi dua kelompok data yaitu *in-sample* dan *out-sample*.
2. Mengestimasi parameter. Parameter diestimasi dengan menggunakan *conditional least square estimation*. Estimasi

dilakukan sampai ditemukan parameter yang signifikan dalam model. Apabila terjadi kesulitan dalam menemukan parameter yang signifikan, maka langkah yang perlu dilakukan adalah kembali melakukan identifikasi model untuk mengetahui karakteristik data hingga menemukan orde p dan q .

3. Melakukan pemeriksaan diagnostik. Setelah model memiliki parameter yang signifikan, maka residual diperiksa atas asumsi residual *white noise* dan berdistribusi normal. Apabila residual tidak *white noise*, maka hal yang perlu dilakukan adalah identifikasi model kembali untuk menentukan orde p atau q yang signifikan. Apabila residual tidak berdistribusi normal, maka hal yang perlu dilakukan adalah identifikasi *outlier* sampai residual berdistribusi normal.
4. Memilih model yang terbaik. Beberapa alternatif model yang didapatkan diseleksi menggunakan kriteria kebaikan model MAPE dan RMSE.

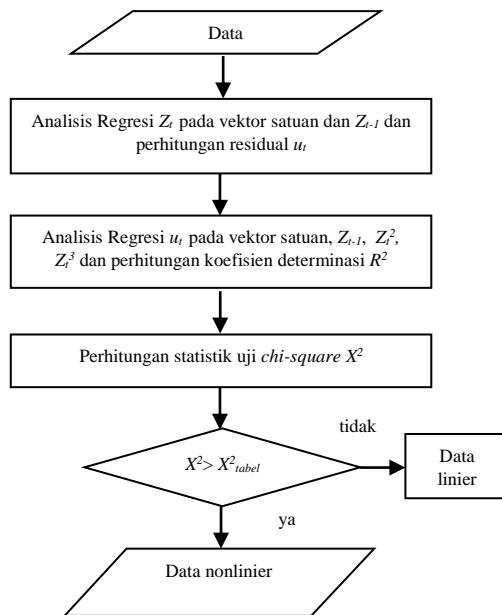
Diagram alir penelitian menggunakan ARIMA ditunjukkan oleh Gambar 3.1. Model ARIMA merupakan model dari pendekatan linier sehingga untuk menganalisis *time series* yang non-linier perlu pendekatan *soft computing*. Pengujian linieritas dapat dilakukan untuk menguji linieritas data jumlah penumpang. Pengujian yang digunakan menggunakan *R software*. Berikut ini merupakan langkah analisis yang dilakukan dalam pengujian linieritas sedangkan diagram alir dapat dilihat pada Gambar 3.2.

1. Melakukan analisis regresi variabel dependen yaitu jumlah penumpang (Z_t) dengan variabel independen yaitu vektor satuan dan lag 1 dari variabel dependen jumlah penumpang (Z_{t-1}) dan menghitung residual (u_t) dari hasil regresi. Lag yang digunakan dalam analisis regresi ini didasarkan pada *default* yang terdapat pada *R software* yaitu lag 1.



Gambar 3.1 Diagram Alir Metode ARIMA

2. Meregresikan residual yang dihasilkan pada langkah 1 pada vektor satuan, lag 1 dari variabel dependen jumlah penumpang, dan dua prediktor tambahan yaitu suku kuadrat dan suku kubik dari variabel dependen jumlah penumpang kemudian menghitung koefisien determinasi dari analisis regresi tersebut.
3. Menghitung statistik uji *chi-square* yaitu dengan mengalikan koefisien determinasi dengan jumlah pengamatan.
4. Membandingkan statistik uji *chi-square* dengan nilai *chi-square* pada tabel distribusi *chi-square*. Apabila statistik uji *chi-square* lebih dari nilai *chi-square* pada tabel distribusi *chi-square* maka dapat menolak hipotesis nol yang menyatakan bahwa data linier.

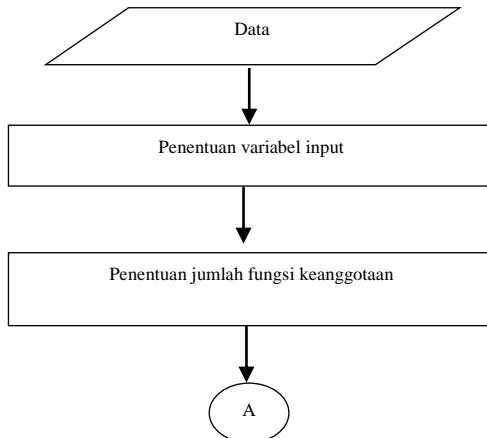


Gambar 3.2 Diagram Alir Uji Linieritas

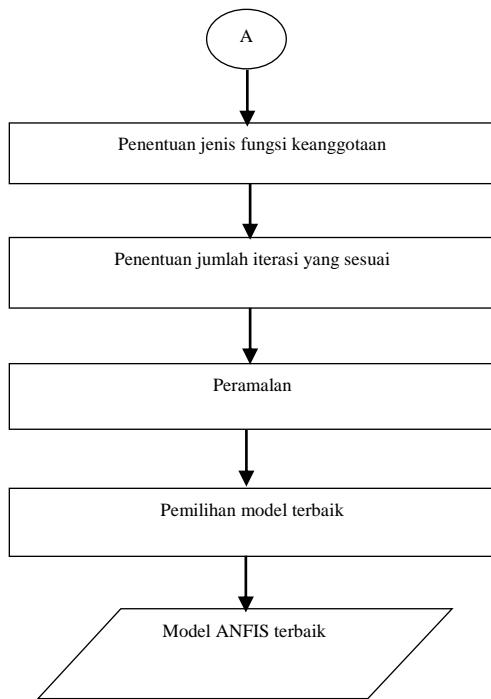
Berikut ini merupakan uraian dari langkah analisis menggunakan ANFIS dan diagram alir ditunjukkan Gambar 3.3.

1. Menentukan variabel masukan berdasarkan orde p yang signifikan pada PACF berdasarkan data yang telah stasioner ataupun dapat melakukan penjabaran model ARIMA.
2. Menentukan jumlah fungsi keanggotaan yang sesuai untuk masing-masing fungsi keanggotaan.
3. Menentukan jenis fungsi keanggotaan. Adapun jenis fungsi keanggotaan yang digunakan adalah fungsi keanggotaan *trapezoidal*, *generalized bell*, *gaussian*, *triangular*, dan *pi*.
4. Melakukan iterasi sampai nilai parameter konvergen dengan error yang minimum.
5. Melakukan peramalan dari masing-masing kombinasi jenis *input* dan jenis fungsi keanggotaan.
6. Memilih model yang terbaik berdasarkan kriteria kebaikan MAPE dan RMSE.

Pemodelan ANFIS yang telah dilakukan menghasilkan model terbaik, sehingga dalam hal ini model terbaik ANFIS dibandingkan dengan model terbaik ARIMA.



Gambar 3.3 Diagram Alir Pemodelan ANFIS



Gambar 3.3 Diagram Alir Pemodelan ANFIS (Lanjutan)

BAB IV

ANALISIS DAN PEMBAHASAN

4.1 Eksplorasi Data Jumlah Penumpang Kereta Api Kertajaya

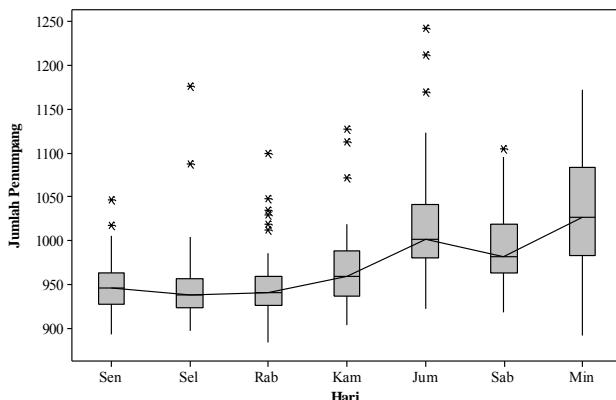
Kereta api Kertajaya merupakan salah satu kereta kelas ekonomi yang menjadi alternatif mode transportasi masyarakat untuk melakukan perjalanan untuk kepentingan tertentu. Adapun masyarakat memilih kereta api sebagai mode transportasi untuk pulang ke kampung halaman maupun kembali ke tempat bekerja atau sekolah, mengunjungi tempat hiburan tertentu, dan lain sebagainya. Kepentingan-kepentingan masyarakat yang telah disebutkan sebelumnya berbeda-beda tergantung pada hari ketika masyarakat melakukan perjalanan sehingga jumlah penumpang setiap harinya berbeda pula, maka penting untuk mengetahui karakteristik jumlah penumpang yang dilihat berdasarkan hari. Berikut ini ditampilkan eksplorasi data jumlah penumpang dengan menggunakan statistika deskriptif untuk mengetahui karakteristik jumlah penumpang .

Tabel 4.1 Statistika Deskriptif Data Jumlah Penumpang Berdasarkan Hari

Hari	Jumlah Hari (<i>n</i>)	Rata-rata	Variansi	Min	Median	Maks
Senin	53	947	898.44	893	946	1046
Selasa	53	947	1908.60	897	938	1176
Rabu	53	950	1558.87	884	941	1100
Kamis	53	967	1929.03	904	959	1127
Jumat	53	1016	4131.60	922	1002	1242
Sabtu	53	994	1927.05	918	982	1105
Minggu	53	1031	4731.70	892	1026	1172

Selama Bulan Mei 2014 sampai dengan Bulan Mei 2015 terdapat masing-masing 53 hari Senin, Selasa, sampai dengan hari Minggu. Berdasarkan statistika deskriptif, diketahui rata-rata jum-

lah penumpang paling sedikit terjadi pada hari Senin dan Selasa yaitu sebesar 947 penumpang karena pada hari tersebut merupakan hari-hari kerja/ sekolah sehingga masyarakat lebih sedikit melakukan perjalanan jauh, sedangkan pada hari Jumat dan minggu terdapat rata-rata jumlah penumpang paling tinggi yaitu sebesar 1016 dan 1031 penumpang karena pada hari-hari tersebut merupakan akhir pekan . Namun, pada dua hari tersebut memiliki variansi yang besar sehingga dapat dikatakan jumlah penumpang pada hari Jumat dan Minggu memiliki keragaman yang besar. Diketahui, jumlah penumpang paling tinggi adalah sebesar 1242 penumpang yang terjadi pada hari Jumat dan terendah pada hari Rabu yaitu sebesar 884 penumpang. Nilai-nilai tersebut atau besar jumlah penumpang dapat menjadi pengamatan yang tidak biasa atau *outlier* apabila berada di atas nilai sebesar $Q_3 + 1.5(Q_3 - Q_1)$ dan berada di bawah nilai $Q_1 - 1.5(Q_3 - Q_1)$. Adapun Q_3 merupakan kuartil ke-3 dan Q_1 merupakan kuartil ke-1. Berdasarkan *boxplot*, *outlier* terdeteksi berada di atas $Q_3 + 1.5(Q_3 - Q_1)$. Adapun statistika deskriptif yang secara grafis dapat memberikan informasi tambahan mengenai karakteristik jumlah penumpang yaitu *box-plot*. *Boxplot* data jumlah penumpang dapat ditunjukkan oleh Gambar 4.1 berikut ini.



Gambar 4.1 Boxplot Data Jumlah Penumpang Berdasarkan Hari

Secara grafis, *boxplot* mendeskripsikan *five number summary* (median, kuartil ke-1, kuartil ke-3, nilai minimum, dan nilai maksimum) dan dapat mendeteksi adanya jumlah penumpang yang tidak biasa atau *outlier* pada jumlah penumpang. Berdasarkan karakteristik hari, median menunjukkan nilai yang tinggi pada hari Jumat dan Minggu. Jumlah penumpang yang tinggi dapat dikatakan cenderung terjadi pada hari Jumat dan Minggu yang merupakan akhir pekan di mana hari Jumat digunakan untuk menuju ke kampung halaman dan hari Minggu untuk kembali ke tempat bekerja. Hal tersebut menunjukkan bahwa karakteristik jumlah penumpang cenderung berbeda pada setiap hari dan memiliki unsur musiman dalam tujuh hari karena cenderung terdapat perulangan setiap tujuh hari. Beberapa *outlier* juga dapat deteksi oleh *boxplot* berdasarkan karakteristik hari misalnya pada hari Sabtu terdapat satu *outlier* yaitu sebanyak 1105 penumpang dan diketahui hari tersebut merupakan satu hari setelah cuti bersama hari natal terjadi.

Selain karakteristik jumlah penumpang berdasarkan hari, perlu juga untuk mengetahui karakteristik jumlah penumpang setiap bulannya. Berikut ini ditunjukkan statistika deskriptif data jumlah penumpang ditinjau berdasarkan bulan.

Tabel 4.2 Statistika Deskriptif Data Jumlah Penumpang Berdasarkan Bulan

Bulan	Jumlah Hari	Rata-rata	Variansi	Min.	Median	Maks.
Mei 2014	31	1007	3221.30	934	982	1160
Juni 2014	30	966	1411.89	898	963	1063
Juli 2014	31	979	3074.49	884	984	1176
Agustus 2014	31	946	712.42	910	938	1005
September 2014	30	983	4575.50	904	970	1242
Oktober 2014	31	982	3765.20	897	959	1170
November 2014	30	984	2655.91	914	975	1095

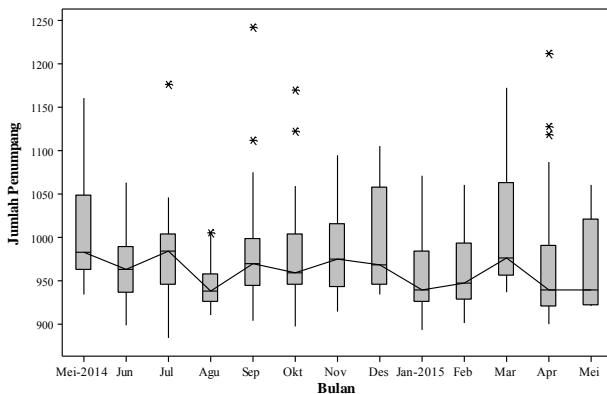
Tabel 4.2 Statistika Deskriptif Data Jumlah Penumpang Berdasarkan Bulan (Lanjutan)

Bulan	Jumlah Hari	Rata-rata	Variansi	Min.	Median	Maks.
Desember 2014	31	995	3540.20	934	968	1105
Januari 2015	31	955	1871.49	893	939	1071
Februari 2015	28	961	1958.44	901	947	1061
Maret 2015	31	1013	5367.00	936	976	1172
April 2015	30	972	5960.70	900	939	1212
Mei 2015	6	965	3315.80	920	939	1061

Data jumlah penumpang yang digunakan yaitu dari 1 Mei 2014 sampai dengan 6 Mei 2015 menyebutkan bahwa terdapat jumlah hari yang berbeda setiap bulan. Adapun rata-rata jumlah penumpang tertinggi terjadi pada Bulan Mei 2014 dan Bulan Maret 2015 yaitu sebesar 1007 dan 1013 penumpang diindikasikan karena pada Bulan Mei 2014 tiket kereta api Kertajaya kembali disubsidi sehingga masyarakat memilih untuk menikmati tarif subsidi kereta begitu pula Bulan Maret 2015 tiket kereta api Kertajaya kembali disubsidi setelah sebelumnya pada Bulan Februari dan Januari 2015 tiket mengalami kenaikan. Hal tersebut ditunjukkan pula pada Bulan Januari 2015 dan Bulan Februari 2015 memiliki rata-rata jumlah penumpang yang paling rendah yaitu sebesar 955 dan 961 penumpang diindikasikan karena tiket kereta api naik. Jumlah penumpang yang beragam setiap harinya dalam satu bulan terjadi pada Bulan Maret 2015 dan Bulan April 2015, hal tersebut ditunjukkan dari variansi yang besar masing-masing sebesar 5367 dan 5960. Secara visual, *boxplot* data jumlah penumpang berdasarkan bulan dapat ditunjukkan oleh Gambar 4.2.

Boxplot yang ditunjukkan oleh Gambar 4.2 merupakan *boxplot* yang didasarkan pada setiap bulan. Secara grafis, jumlah penumpang kereta api Kertajaya selama Bulan Mei 2014 s.d Mei 2015 dapat dikatakan fluktuatif atau naik turun didasarkan pada median data. Indikasi pengaruh tiket kereta api yang disesuaikan

dapat pula ditunjukkan secara grafis oleh *boxplot*. Bulan Januari 2015 s.d Bulan Februari 2015 median terus menurun hingga Bulan Maret 2015 sempat mengalami kenaikan setelah itu turun kembali pada Bulan April 2015. Hal tersebut terjadi diindikasikan akibat dari kembalinya tarif kereta api ekonomi jarak jauh pada tarif normal (tarif tanpa subsidi) pada Bulan Januari 2015 sampai Bulan Februari 2015 dan tarif disubsidi kembali pada Bulan Maret 2015, namun kembali pada tarif normal pada Bulan April 2015. Selain itu, *boxplot* menunjukkan terdapat satu *outlier* pada data jumlah penumpang misalnya pada Bulan Juli 2014. *Outlier* ditemukan pada tanggal 29 Juli 2014 yang merupakan hari kedua libur nasional idul fitri. Selain itu, *outlier* mendominasi terjadi di atas batas $Q_3 + 1.5(Q_3 - Q_1)$.



Gambar 4.2 Boxplot Data Jumlah Penumpang Berdasarkan Bulan

Berdasarkan eksplorasi data jumlah penumpang yang dihasilkan, diketahui bahwa jumlah penumpang harian memiliki karakteristik yang berbeda setiap harinya sehingga membuat jumlah penumpang dapat menjadi tinggi atau rendah. Begitu pula setiap bulannya menunjukkan karakteristik jumlah penumpang sehingga terdapat bulan-bulan tertentu yang cenderung memiliki jumlah penumpang yang tinggi yaitu Bulan Mei 2014 dan Maret 2015.

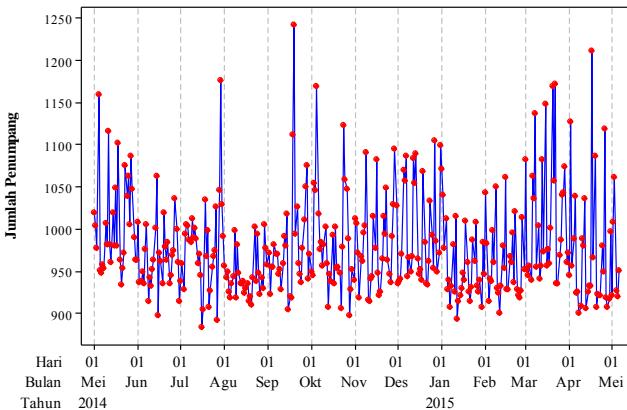
4.2 Peramalan Jumlah Penumpang Kereta Api Kertajaya Menggunakan ARIMA

Analisis *times series* yang diterapkan pada jumlah penumpang bertujuan untuk meramalkan jumlah penumpang di masa mendatang. Peramalan jumlah penumpang kereta api Kertajaya dilakukan dengan menggunakan prosedur Box Jenkins yaitu ARIMA. Adapun dalam penelitian ini terdapat empat prosedur yang dilakukan hingga menemukan model ARIMA yang terbaik untuk meramalkan jumlah penumpang kereta api Kertajaya. Berikut ini merupakan prosedur yang diterapkan untuk meramalkan jumlah penumpang.

4.2.1 Identifikasi Model ARIMA untuk Meramalkan Jumlah Penumpang Kereta Api Kertajaya

Identifikasi model ARIMA dalam penelitian ini digunakan untuk mengetahui kebutuhan transformasi yang tepat untuk data jumlah penumpang seperti transformasi untuk menstabilkan variansi dan transformasi untuk pembedaan (*differencing*), menentukan karakteristik data *out sample*, serta menentukan orde p atau q yang tepat untuk model. Langkah pertama adalah membuat plot *time series* sebagai visualisasi data jumlah penumpang harian yaitu selama 371 hari mulai tanggal 1 Mei 2014 sampai dengan 6 Mei 2015 untuk mengetahui karakteristik jumlah penumpang. Plot *time series* yang memberikan visualisasi jumlah penumpang dapat ditunjukkan oleh Gambar 4.3.

Visualisasi plot *time series* dari data jumlah penumpang menunjukkan bahwa jumlah penumpang kereta api Kertajaya cukup fluktuatif. Jumlah penumpang kereta api Kertajaya mencapai jumlah tertinggi sepanjang Bulan Mei 2015 sampai dengan Bulan Mei 2015 yaitu 1242 orang perhari dan paling sedikit terdapat 884 orang perhari. Rata-rata jumlah penumpang sebesar 978 orang perhari dengan variansi yang cukup besar yaitu 3447.51. Berdasarkan visualisasi, diindikasikan bahwa data jumlah penumpang tidak stasioner dalam variansi dan rata-rata yang dapat diketahui dari penyebaran jumlah penumpang yang tidak berada di sekitar variansi dan rata-rata.

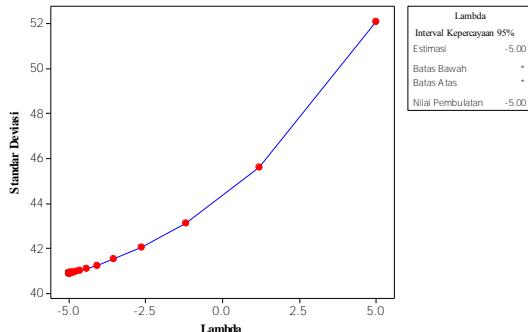


Gambar 4.3 Plot *Time Series* Jumlah Penumpang Kereta Api Kertajaya

Data jumlah penumpang dapat di bagi menjadi data *in sample* dan *out sample* berdasarkan karakteristik data untuk proses peramalan. Visualisasi dari plot *time series* dan *boxplot* menunjukkan bahwa data memiliki karakteristik yang berbeda pada masing-masing hari dan memiliki unsur musiman sehingga data *in-sample* berupa data jumlah penumpang sebanyak 357 hari mulai tanggal 1 Mei 2014 sampai dengan 22 April 2015 sedangkan data *out sample* terdiri dari 14 hari mulai tanggal 23 April 2015 sampai dengan 6 Mei 2015. Setelah itu, data jumlah penumpang dapat dianalisis lebih lanjut. Data jumlah penumpang yang tidak stasioner dalam variansi dapat di periksa pula menggunakan plot *Box-Cox*.

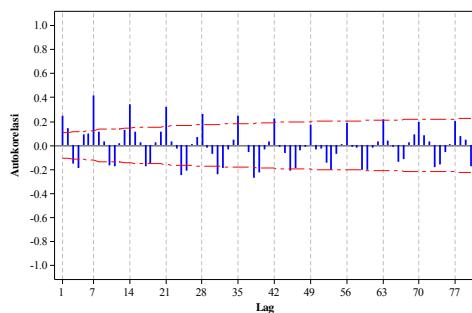
Plot *Box-Cox* menyatakan bahwa batas bawah kendali lambda adalah tidak terhingga begitu juga dengan batas atas kendali lambda, maka data jumlah penumpang memang tidak stasioner dalam variansi. Apabila menggunakan transformasi dengan menggunakan nilai pembulatan -5.00 maka data asli hasil dari transformasi menjadi nilai yang mendekati nol. Namun, dalam hal ini lebih baik tidak melakukan transformasi karena tidak di-

ketahui lambda yang tepat untuk transformasi sehingga data yang digunakan selanjutnya merupakan data tanpa transformasi.

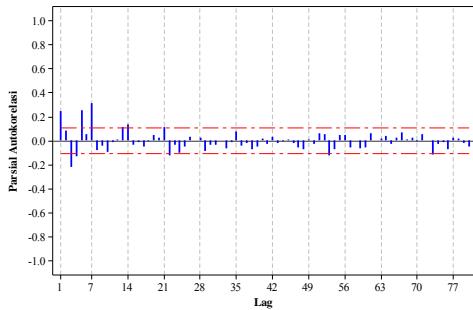


Gambar 4.4 Plot Box-Cox Data Jumlah Penumpang

Indikasi data jumlah penumpang yang tidak stasioner dalam rata-rata dapat juga divisualisasikan oleh plot ACF dan PACF data *in sample*. Adapun plot ACF dan PACF dapat ditunjukkan oleh Gambar 4.5. Plot ACF menunjukkan bahwa terdapat pola sinusoidal teredam sedangkan PACF menunjukkan pola *cut off*. Visualisasi juga menunjukkan bahwa autokorelasi yang tinggi ditemukan hampir disetiap lag ke-7 dan kelipatannya begitu juga dengan parsial autokorelasi.



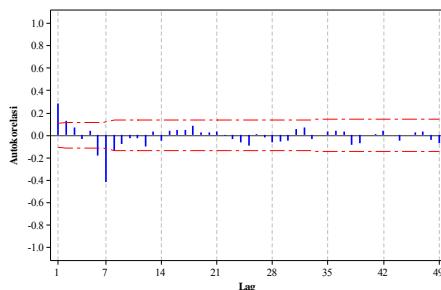
(a)



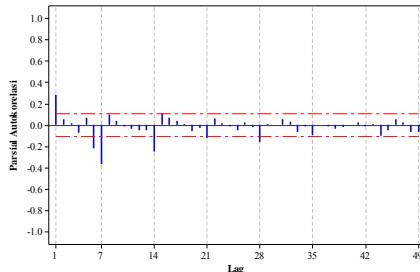
(b)

Gambar 4.5 Plot (a) ACF dan (b) PACF Data Jumlah Penumpang

Plot ACF dan PACF pada Gambar 4.5 menunjukkan perlunya pembedaan satu kali dari $(1-B^s)Z_t$ dengan $s=7$ karena data jumlah penumpang tidak stasioner dalam rata-rata musiman sebanyak tujuh. Sehingga plot ACF dan PACF untuk data jumlah penumpang yang telah dilakukan pembedaan ditunjukkan oleh Gambar 4.6. Pembedaan musiman yang dihasilkan menunjukkan bahwa terdapat indikasi data masih tidak stasioner dalam rata-rata sehingga data hasil pembedaan musiman sebanyak tujuh dilakukan pembedaan kembali dengan pembedaan $(1-B)Z_t$ sehingga data menerima perlakuan pembedaan $(1-B)(1-B^7)Z_t$.



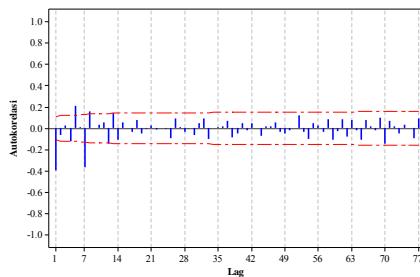
(a)



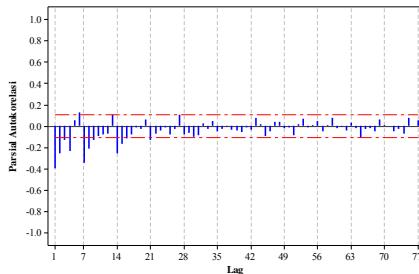
(b)

Gambar 4.6 Plot (a) ACF dan (b) PACF Data Jumlah Penumpang dengan Pembedaan $(1-B^7)Z_t$

Pada Gambar 4.7 dapat ditunjukkan plot ACF dan PACF untuk data yang telah dilakukan pembedaan regular dan musiman. Berdasarkan plot PACF diketahui bahwa pada lag ke-1,2,3, dan 6 signifikan sedangkan pada plot ACF terjadi lag yang signifikan pada lag ke-1 dan kelipatan tujuh sehingga model yang dapat dibentuk adalah ARIMA $([1,2,3,6],1,1)(0,1,1)^7$. Selain itu, lag signifikan pada lag ke-4 dan ke-6 pada plot PACF sedangkan ACF signifikan pada lag ke-1 dan 7 atau kelipatan tujuh sehingga model adalah ARIMA $([4,6],1,1)(0,1,1)^7$. Selanjutnya, model juga dapat dibentuk dari plot ACF dengan lag yang signifikan pada lag ke-1, ke-4, dan ke-7 atau musiman tujuh sehingga dapat dibentuk model ARIMA $(0,1,[1,4])(0,1,1)^7$.



(a)



(b)

Gambar 4.7 Plot (a) ACF dan (b) PACF Data Jumlah Penumpang dengan Pembedaan $(1-B)^7(1-B^7)Z_t$

4.2.2 Estimasi Parameter Model ARIMA

Identifikasi model pada prosedur sebelumnya menghasilkan beberapa model musiman tujuh dari data yang telah dilakukan pembedaan reguler dan musiman yaitu ARIMA $([1,2,3,6],1,1)$ $(0,1,1)^7$, ARIMA $([4,6],1,1)$ $(0,1,1)^7$, serta ARIMA $(0,1, [1,4])$ $(0,1,1)^7$. Pada prosedur Box Jenkins berikutnya, ketiga model tersebut dilakukan estimasi parameter sedemikian hingga parameter yang dihasilkan pada masing-masing model signifikan pada taraf signifikansi 5%. Berikut ini ditunjukkan signifikansi parameter dari ketiga model ARIMA yang telah diidentifikasi.

Tabel 4.3 Signifikansi Parameter Model ARIMA $([1,2,3,6],1,1)(0,1,1)^7$

Parameter	Estimasi	Standar Error	t	$t_{\frac{0.05}{2}, 357-6}$	P-Value
θ_4	0.4694	0.0667	7.03	1.9667	<0.0001
Θ_1	0.7457	0.0401	18.60	1.9667	<0.0001
ϕ_1	-0.6655	0.0510	-13.06	1.9667	<0.0001
ϕ_2	-0.5139	0.0639	-8.05	1.9667	<0.0001
ϕ_3	-0.4514	0.0674	-6.70	1.9667	<0.0001
ϕ_6	-0.0986	0.0479	-2.06	1.9667	0.0404

Signifikansi parameter pada model ARIMA ([1,2,3,6],1,1) ($0,1,1$)⁷ menghasilkan sebanyak enam parameter yang signifikan sehingga nilai $t_{\frac{0.05}{2},357-6} = 1.9667$. Berdasarkan nilai dari t_{hitung} , diketahui bahwa keenam parameter memenuhi kondisi $|t| > t_{\frac{0.05}{2},357-6}$ atau dapat ditinjau dari $p\text{-value}$ yang kurang dari taraf signifikansi 5%. Adapun hipotesis nol yaitu parameter model sama dengan nol ditolak sehingga dapat disimpulkan bahwa parameter telah signifikan. Signifikansi parameter pada model ARIMA ([4,6],1,1) ($0,1,1$)⁷ dapat ditunjukkan pada Tabel 4.4 berikut ini.

Tabel 4.4 Signifikansi Parameter Model ARIMA ([4,6],1,1) ($0,1,1$)⁷

Parameter	Estimasi	Standar Error	t	$t_{\frac{0.05}{2},357-4}$	P-Value
θ_1	0.7281	0.0384	18.96	1.9667	<0.0001
Θ_1	0.7414	0.0371	19.97	1.9667	<0.0001
ϕ_4	-0.1190	0.0546	-2.18	1.9667	0.0298
ϕ_6	-0.1116	0.0554	-2.01	1.9667	0.0448

Lain halnya dengan model sebelumnya, model ARIMA ([4,6],1,1) ($0,1,1$)⁷ menghasilkan empat parameter yang signifikan pada taraf signifikansi 5%. Hal tersebut dapat ditunjukkan dari kondisi $|t| > t_{\frac{0.05}{2},357-4}$ ataupun $p\text{-value} < \alpha$ dengan taraf signifikansi

$\alpha = 0.05$. Signifikansi parameter untuk model selanjutnya yaitu model ARIMA (0,1, [1,4]) ($0,1,1$)⁷ dapat ditunjukkan oleh Tabel 4.5 berikut ini.

Tabel 4.5 Signifikansi Parameter Model ARIMA (0,1, [1,4]) ($0,1,1$)⁷

Parameter	Estimasi	Standar Error	t	$t_{\frac{0.05}{2},357-3}$	P-Value
θ_1	0.7285	0.0387	18.81	1.9667	<0.0001
θ_4	0.0811	0.0390	2.08	1.9667	0.0382
Θ_1	0.7307	0.0386	18.94	1.9667	<0.0001

Estimasi parameter pada model ARIMA (0,1,[1,4])(0,1,1)⁷ menunjukkan bahwa ketiga parameter signifikan pada taraf signifikansi 5%. Ketiga parameter signifikan karena $|t| > t_{\frac{0.05}{2}, 357-3}$ atau dapat diketahui dari *p-value* yang kurang dari taraf signifikansi $\alpha = 0.05$. Setelah dilakukan estimasi, maka tahap selanjutnya adalah pemeriksaan residual model yang meliputi residual *white noise* dan berdistribusi normal.

4.2.3 Pemeriksaan Diagnostik terhadap Residual Model ARIMA

Adapun pemeriksaan diagnostik residual model dilakukan untuk mengetahui apakah residual yang satu dengan yang lainnya tidak memiliki korelasi (independen) dan memiliki pola yang menyebar atau acak (identik) serta berdistribusi normal. Berikut ini merupakan pemeriksaan residual dengan menggunakan statistik uji *Q* yang mengikuti distribusi *chi square*.

Tabel 4.6 Pemeriksaan Diagnostik *White Noise* terhadap Residual Model ARIMA ([1,2,3,6],1,1)(0,1,1)⁷

Sampai Lag ke-	X^2_{hitung}	db	$X^2_{(1-0.05),db}$	P-Value
6	.	0	.	.
12	3.00	6	12.59	0.8087
18	7.68	12	21.03	0.8094
24	9.53	18	28.87	0.9462
30	12.71	24	36.42	0.9707
36	17.34	30	43.77	0.9683
42	19.16	36	51.00	0.9904
48	21.46	42	58.12	0.9964

Pengujian residual kali ini menguji hipotesis nol yaitu residual telah *white noise* sehingga berdasarkan *chi square* hingga lag ke-48 yang menunjukkan bahwa $X^2_{hitung} < X^2_{(1-0.05),db}$, maka dapat diputuskan untuk gagal menolak hipotesis nol, sehingga residual

model telah *white noise*. Pemeriksaan diagnostik *white noise* juga dilakukan pada model ARIMA ([4,6],1,1) (0,1,1)⁷ yang diperlihatkan pada Tabel 4.7.

Tabel 4.7 Pemeriksaan Diagnostik *White Noise* terhadap Residual Model ARIMA ([4,6],1,1) (0,1,1)⁷

Sampai Lag ke-	X^2_{hitung}	db	$X^2_{(1-0.05),db}$	P-Value
6	3.96	2	5.99	0.1379
12	8.02	8	15.51	0.4311
18	11.83	14	23.68	0.6201
24	14.69	20	31.41	0.7941
30	19.1	26	38.89	0.8323
36	23.27	32	46.19	0.8697
42	25.24	38	53.38	0.9442
48	29.17	44	60.48	0.9583

Model ARIMA ([4,6],1,1) (0,1,1)⁷ juga memiliki residual yang *white noise* hingga lag ke-48. Hal tersebut dibuktikan dengan adanya statistik uji *chi square* yang lebih kecil dari pada $X^2_{(1-0.05),db}$ dan juga ditandai dengan *p-value* yang lebih dari $\alpha = 0.05$. Pengujian residual model ARIMA (0,1,[1,4]) (0,1,1)⁷ ditunjukkan oleh Tabel 4.8 berikut ini.

Tabel 4.8 Pemeriksaan Diagnostik *White Noise* terhadap Residual Model ARIMA (0,1, [1,4]) (0,1,1)⁷

Sampai Lag ke-	X^2_{hitung}	db	$X^2_{(1-0.05),db}$	P-Value
6	7.54	3	7.81	0.0566
12	9.41	9	16.92	0.4000
18	14.5	15	25.00	0.4877
24	16.96	21	32.67	0.7133
30	21.47	27	40.11	0.7639
36	25.6	33	47.40	0.8175
42	27.96	39	54.57	0.9058
48	31.34	45	61.66	0.9389

Hasil pengujian menghasilkan kesimpulan bahwa residual model ARIMA (0,1, [1,4]) (0,1,1)⁷ *white noise* ditunjukkan dari hasil perhitungan *chi-square* dan *p-value* yang lebih dari dari taraf signifikansi $\alpha = 0.05$. Berdasarkan pengujian residual *white noise*, ketiga model memenuhi asumsi residual *white noise* sehingga pengamatan sekarang tidak memiliki autokorelasi dengan pengamatan sebelumnya dan cenderung memiliki pola yang random/acak. Tahap selanjutnya adalah pemeriksaan diagnostik residual berdistribusi normal.

Tabel 4.9 Pemeriksaan Diagnostik Distribusi Normal terhadap Residual Model

Model ARIMA	D	$D_{(1-0.05;n>40)}$	P-Value
([1,2,3,6],1,1) (0,1,1) ⁷	0.0892	0.0728	<0.01
([4,6],1,1) (0,1,1) ⁷	0.0942	0.0728	<0.01
(0,1, [1,4]) (0,1,1) ⁷	0.0939	0.0728	<0.01

Residual yang didapatkan pada ketiga model ini adalah sebanyak data *in-sample* dikurangi dengan delapan (357-8=349) sehingga kuantil dari statistik kolmogorov smirnov dalam taraf signifikansi 5% adalah sebesar $D_{(1-0.05;n=349)} = 1.36/\sqrt{349} = 0.0728$. Pada pengujian ini, hipotesis yang diuji adalah bahwa distribusi dari residual model adalah distribusi normal. Berdasarkan pengujian, ketiga model memiliki kondisi $D > D_{(1-0.05;349)}$ sehingga diputuskan untuk menolak hipotesis nol, berarti residual dari ketiga model tidak berdistribusi normal. Ketidak normalan dari residual disebabkan oleh *outlier* pada pengamatan atau data sehingga penanganan yang dilakukan adalah dengan mendeteksi *outlier* kemudian memasukkannya ke dalam model ARIMA.

4.2.4 Deteksi *Outlier* pada Model ARIMA

Residual pada ketiga model yang tidak berdistribusi normal menunjukkan adanya *outlier* pada data jumlah penumpang kereta api. Deteksi *outlier* yang dilakukan dalam penelitian ini menggu-

nakan taraf signifikansi sebesar 0.135 % dengan maksimum pendekstrian sebesar 30. Berikut ini merupakan hasil dari deteksi *outlier* pada ketiga model.

Tabel 4.10 Signifikansi Parameter Model ARIMA ([1,2,3,6],1,1) (0,1,1)⁷ dengan Deteksi *Outlier*

Para-meter	Estimasi	Standar Error	T	P-Value	Tipe Outlier
θ_4	0.4263	0.0663	6.43	<0.0001	-
θ_6	0.1396	0.0527	2.65	0.0085	-
Θ_1	0.6813	0.0433	15.72	<0.0001	-
ϕ_1	-0.6151	0.0545	-11.29	<0.0001	-
ϕ_2	-0.4800	0.0641	-7.49	<0.0001	-
ϕ_3	-0.4224	0.0673	-6.27	<0.0001	-
ω_{142}	197.8149	40.3184	4.91	<0.0001	Additive
ω_{172}	-95.0264	39.5052	-2.41	0.0167	Additive
ω_{338}	-146.2274	40.5297	-3.61	0.0004	Additive
ω_{351}	-89.5601	43.5885	-2.05	0.0407	Additive

Deteksi *outlier* pada model ARIMA ([1,2,3,6],1,1) (0,1,1)⁷ tidak merubah model awal dan ditemukan sebanyak empat *outlier* yang signifikan dengan tipe yang sama yaitu *additive*. Pada deteksi *outlier* tersebut, diketahui model ARIMA ([1,2,3,6],1,1) (0,1,1)⁷ dengan empat *outlier* yang signifikan terhadap model masih ditemukan sebanyak 24 *outlier* dari pendekstrian *outlier* sebanyak 30. Keseleruhan *outlier* yang ditemukan dilakukan signifikansi satu persatu terhadap model dengan taraf signifikansi sebesar 5%. Namun, hingga dimasukkan *outlier* ke-24 atau *outlier* yang terakhir, tidak ada lagi *outlier* yang signifikan terhadap model dan residual model tetap tidak berdistribusi normal. Sehingga dalam hal ini model ARIMA ([1,2,3,6],1,1) (0,1,1)⁷ dengan empat *outlier* memiliki residual yang telah *white noise* namun tidak berdistribusi normal. Selanjutnya, deteksi *outlier* pada model ARIMA ([4,6],1,1) (0,1,1)⁷ dapat ditunjukkan oleh Tabel 4.11.

Tabel 4.11 Signifikansi Parameter
Model ARIMA ([4,6],1,1) (0,1,1)⁷dengan Deteksi Outlier

Parame- ter	Estimasi	Standar Error	t	P-value	Outlier
θ_1	0.8101	0.0482	16.80	<.0001	-
Θ_1	0.6802	0.0428	15.91	<.0001	-
ϕ_1	0.2205	0.0746	2.96	0.0033	-
ϕ_6	-0.1525	0.0571	-2.67	0.0079	-
ω_{142}	199.7619	39.3498	5.08	<.0001	Additive
ω_{338}	-163.2736	39.9802	-4.08	<.0001	Additive
ω_{172}	-86.2940	38.6318	-2.23	0.0262	Additive
ω_{351}	-93.5305	42.6860	-2.19	0.0291	Additive
ω_{88}	-161.2107	38.9028	-4.14	<.0001	Additive
ω_{91}	-77.6835	32.9762	-2.36	0.0191	Level Shift

Model ARIMA ([4,6],1,1) (0,1,1)⁷ memiliki enam *outlier* yang signifikan dengan lima berupa *outlier tipe additive* dan satu berupa *outlier tipe level shift*. Dalam hal ini, model ARIMA ([4,6],1,1) (0,1,1)⁷ berubah menjadi model ARIMA ([1,6],1,1) (0,1,1)⁷ dalam proses pendekripsi *outlier* untuk menemukan *outlier* yang signifikan terhadap model ARIMA. Namun deteksi *outlier* dengan taraf signifikansi sebesar 0.135 % masih menemukan 20 *outlier* sehingga dilakukan proses memasukkan model *outlier* kedalam model ARIMA satu persatu untuk dilakukan signifikansi parameter. Namun hingga *outlier* terakhir dimasukkan, tidak ada satupun dari dua puluh *outlier* yang signifikan terhadap model sehingga residual tetap tidak berdistribusi normal. Sama halnya dengan model ARIMA ([1,2,3,6],1,1) (0,1,1)⁷ dengan empat *outlier*, model ARIMA ([4,6],1,1) (0,1,1)⁷ dengan enam *outlier* juga tidak menghasilkan residual yang berdistribusi normal namun telah *white noise*. Hasil deteksi *outlier* pada model ARIMA (0,1, [1,4]) (0,1,1)⁷ ditunjukkan oleh Tabel 4.12 berikut ini.

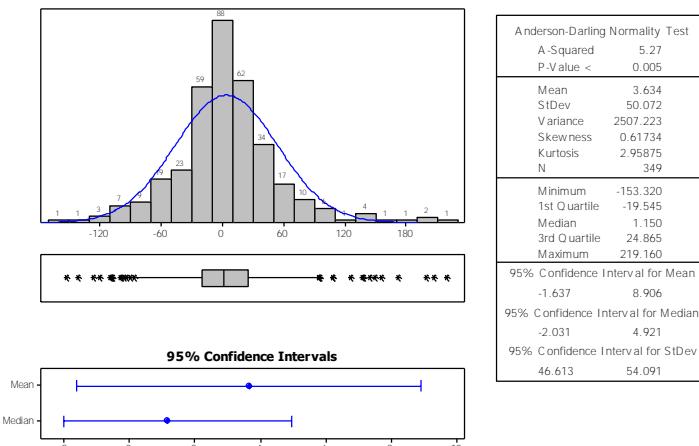
Tabel 4.12 Signifikansi Parameter
Model ARIMA (0,1, [1,4]) (0,1,1)⁷ dengan Deteksi Outlier

Para-meter	Estimasi	Standar Error	t	P-value	Outlier
θ_1	0.7190	0.0398	18.06	<0.0001	-
θ_4	0.0886	0.0395	2.24	0.0258	-
Θ_1	0.7065	0.0403	17.54	<0.0001	-
ω_{142}	220.1660	41.9212	5.25	<0.0001	Additive
ω_{338}	-141.2870	42.7856	-3.30	0.0011	Additive

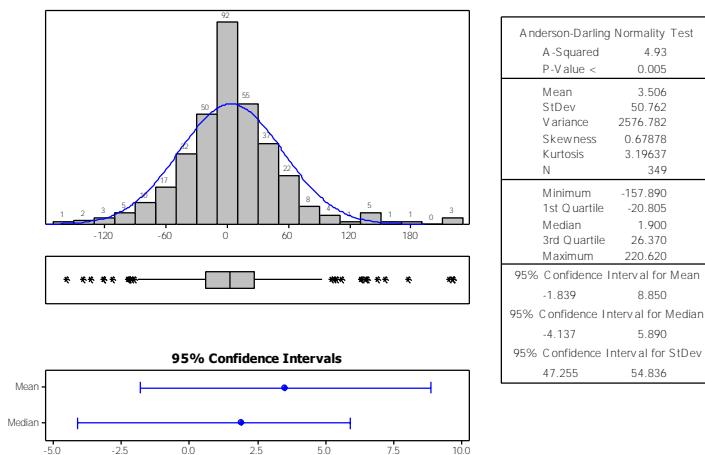
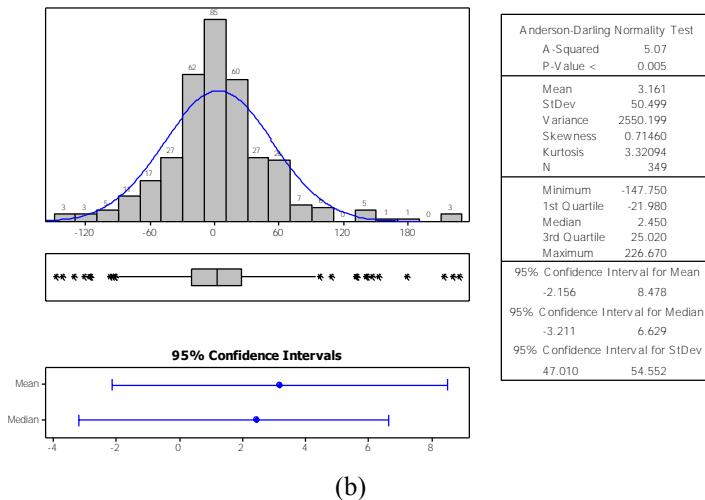
Hasil pendekripsi *outlier* pada model ARIMA (0,1, [1,4]) (0,1,1)⁷ hanya menemukan dua *outlier* yang signifikan terhadap model yaitu dua *outlier* tipe *additive*. Dalam taraf signifikansi deteksi *outlier* sebesar 0.135 % *outlier* masih terdeteksi sebanyak 24 *outlier*. Namun proses memasukkan model *outlier* dalam model secara satu persatu masih tidak menemukan *outlier* yang signifikan dalam model ARIMA dan masih menghasilkan residual yang tidak berdistribusi normal. Sehingga dalam deteksi *outlier* pada ketiga model untuk menghasilkan residual yang memenuhi asumsi berdistribusi normal tidak berhasil dilakukan. Residual model tidak berdistribusi normal bertentangan dengan asumsi residual model yang harus berdistribusi normal dalam prosedur Box Jenkins. Pemeriksaan residual untuk melihat distribusi residual dan karakteristik residual dapat ditunjukkan secara grafis oleh ringkasan grafis pada Gambar 4.8.

Ringkasan grafis menunjukkan empat grafik yaitu histogram dari residual dengan kurva normal, *boxplot*, dan interval kepercayaan untuk rata-rata serta median pada Gambar 4.8. Distribusi data yang tidak simetris ditunjukkan secara matematis oleh statistik *skewness* yaitu residual ketiga model memiliki statistik *skewness* yang positif atau nilai lebih dari nol sehingga dapat disimpulkan bahwa data residual skew ke kanan. Hal tersebut juga dapat ditunjukkan oleh *whisker boxplot* sebelah kiri sedikit lebih panjang dari yang kanan. Distribusi data residual yang tidak normal dapat

ditunjukkan oleh statistik *kurtosis*, di mana ketiga residual memiliki statistik *kurtosis* yang positif. Statistik *kurtosis* menunjukkan bahwa distribusi data residual memiliki kurva yang lebih runcing daripada kurva normal atau dapat disebut juga kurva leptokurtik. Kurva leptokurtik memiliki puncak yang lebih runcing dibandingkan dengan kurva distribusi normal berarti nilai-nilai residual tersebar paling banyak pada titik nol atau mendekati nol. Residual atau *error* yang banyak mengumpul di titik nol (pada histogram) menunjukkan bahwa model menghasilkan residual yang kecil. Residual yang kecil berarti model telah menghasilkan nilai-nilai peramalan yang mendekati data asli/ pengamatan. Selain itu pada ringkasan grafis ditunjukkan pula interval kepercayaan untuk rata-rata dan median yang menunjukkan bahwa kedua interval tidak memiliki panjang yang sama namun terjadi *overlaid* dari kedua interval sehingga dapat disimpulkan bahwa tidak ada perbedaan signifikan antara median dan rata-rata residual ketiga model ARI-MA.



(a)



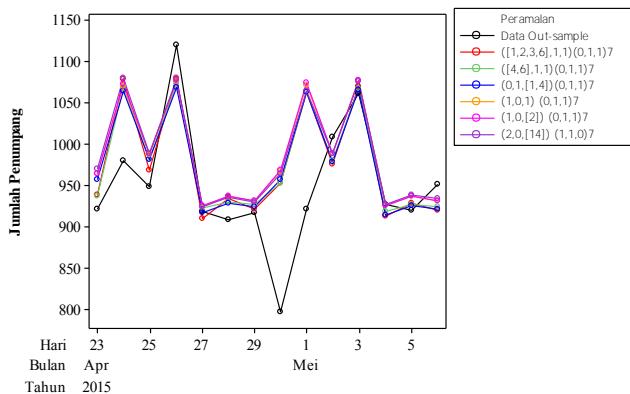
(c)

Gambar 4.8 Ringkasan Grafis pada Residual Model ARIMA:
 (a) $([1,2,3,6],1,1)(0,1,1)^7$; (b) $([4,6],1,1)(0,1,1)^7$; (c) $(0,1,[1,4])(0,1,1)^7$

Berdasarkan ringkasan grafis, ringkasan yang dapat disimpulkan adalah bahwa residual ketiga model tidak berdistribusi normal karena kurva yang terbentuk adalah kurva leptokurtik. Adapun suatu uji signifikansi seperti uji asumsi residual berdistribusi normal tidak selalu dilakukan agar memenuhi asumsi pemodelan. Hal tersebut dikemukakan oleh Kostenko dan Hyndman (2008) dalam peramalan yang dilakukannya dalam bidang bisnis. Peramalan dapat lepas dari suatu uji signifikansi seperti uji asumsi residual dalam pemodelan Box-Jenkins, namun tetap memperhatikan suatu model yang dapat meramalkan nilai-nilai mendatang dengan baik berdasarkan kriteria kebaikan model (misalnya RMSE dan MAPE). Sehingga dalam penelitian ini, ketiga model tidak memenuhi asumsi residual berdistribusi normal. Pada pemodelan ARIMA selanjutnya akan memperhatikan kriteria kebaikan dari model tanpa memasukkan *outlier* dalam model berdasarkan RMSE dan MAPE untuk menemukan model terbaik.

4.2.5 Pemilihan Model ARIMA Terbaik

Pemodelan ARIMA menghasilkan tiga model dari pemodelan data jumlah penumpang yang diterapkan pembedaan regular dan musiman yang memenuhi signifikansi parameter dan residual *white noise*. Selain itu pemodelan jumlah penumpang juga menghasilkan tiga model yang dibentuk dari data yang hanya diterapkan pembedaan seasonal saja yaitu ARIMA (1,0,1) (0,1,1)⁷, ARIMA (1,0,[2]) (0,1,1)⁷ ARIMA (2,0,[14]) (1,1,0)⁷ yang juga telah memenuhi signifikansi parameter dan residual *white noise*. Sehingga dalam hal ini akan dibandingkan keenam model tersebut. Suatu model yang digunakan dalam suatu peramalan dipilih berdasarkan kemampuannya dalam meramalkan nilai-nilai di masa mendatang. Hasil peramalan dari kedua model dapat ditunjukkan secara visual oleh plot *time series*. Perbandingan masing-masing hasil peramalan keenam model dengan data *out-sample* jumlah penumpang sebanyak 14 hari ditunjukkan oleh plot *time series* pada Gambar 4.9.



Gambar 4.9 Perbandingan Data *Out-Sample* dengan
Hasil Peramalan keenam Model ARIMA

Berdasarkan plot *time series*, diketahui bahwa peramalan keenam model memiliki kecenderungan pola yang sama dan telah mengikuti pola data *out-sample*. Namun pada tanggal 30 Mei, peramalan dari keenam model ARIMA sangat jauh dari data *out-sample* hal tersebut akan berakibat pada performansi keakurasi model. Adapun Akurasi model dapat ditunjukkan berdasarkan kriteria kebaikan model, dalam hal ini kriteria yang digunakan adalah RMSE dan MAPE. Kriteria *in-sample* dan *out-sample* diterapkan pada keenam model sebagai berikut ini.

Tabel 4.13 Pemilihan Model Terbaik Berdasarkan
Kriteria Kebaikan Model

Pembelaan	Model ARIMA	Kriteria		Kriteria Out-sample	
		In-sample	RMSE	RMSE	MAPE(%)
$(1-B)$	$([1,2,3,6],1,1)(0,1,1)7$		50.1323	65.0733	4.7277
$(1-B^7)Z_t$	$([4,6],1,1)(0,1,1)^7$		50.5261	64.2621	4.6681

Tabel 4.13 Pemilihan Model Terbaik Berdasarkan Kriteria Kebaikan Model (Lanjutan)

Pembedaan	Model ARIMA	Kriteria <i>In-sample</i>		Kriteria
		RMSE	RMSE	MAPE(%)
	(0,1,[1,4])(0,1,1) ⁷	50.8103	65.3818	4.8032
	(1,0,1) (0,1,1) ⁷	48.7163	69.1343	5.1474
	(1,0,[2]) (0,1,1) ⁷	48.7381	69.7480	5.2009
(1-B ⁷) Z _t	(2,0,[14]) (1,1,0) ⁷	48.5756	68.5717	5.1297

Ketiga model hasil dari pemodelan dengan data yang telah mengalami pembedaan musiman dan regular cenderung menghasilkan RMSE *in-sample* yang lebih besar adapun RMSE terkecil dihasilkan oleh model ARIMA (2,0,[14]) (1,1,0)⁷. Tujuan dari pemodelan adalah peramalan nilai di masa mendatang, sehingga kriteria kebaikan yang digunakan untuk pemilihan model adalah kriteria *out-sample*. Berdasarkan MAPE, ketiga model yang mengalami pembedaan musiman (1-B⁷) Z_t memiliki MAPE yang lebih besar dari pada 5% sebaliknya model dari data dengan pembedaan musiman dan regular (1-B) (1-B⁷)Z_t menghasilkan MAPE kurang dari 5%. Berdasarkan kriteria data *out-sample*, diketahui bahwa model ARIMA ([4,6],1,1)(0,1,1)⁷ memiliki kemampuan yang lebih baik dibandingkan kelima model ARIMA yang lain dalam meramalkan jumlah penumpang dengan MAPE sebesar 4.67% dan RMSE sebesar 64.26. Adapun model ARIMA ([4,6],1,1)(0,1,1)⁷ dapat dituliskan berikut ini.

$$\begin{aligned}
 Z_t = & Z_{t-1} - 0.1190Z_{t-4} + 0.1190Z_{t-5} - 0.1116Z_{t-6} + 1.1116Z_{t-7} - Z_{t-8} \\
 & + 0.1190Z_{t-11} - 0.1190Z_{t-12} + 0.1116Z_{t-13} - 0.1116Z_{t-14} - 0.7281a_{t-1} \\
 & - 0.7414a_{t-7} + 0.5398a_{t-8} + a_t
 \end{aligned}$$

Model ARIMA ([4,6],1,1)(0,1,1)⁷ menunjukkan bahwa jumlah penumpang kereta api kelas ekonomi Kertajaya pada waktu ke *t* dipengaruhi oleh jumlah penumpang pada waktu ke *t-1*, *t-4*, *t-5*, *t-6*, *t-7*, *t-8*, *t-11*, *t-12*, *t-13*, dan *t-14*. Adapun hasil peramalan dari model ARIMA yang terbaik ditunjukkan oleh Tabel 4.51.

4.3 Pemodelan Jumlah Penumpang Kereta Api Kertajaya Menggunakan ANFIS

Pemodelan jumlah penumpang kereta api Kertajaya menggunakan ANFIS dilakukan karena indikasi dari ketidaklinieran data jumlah penumpang kereta api Kertajaya. Sehingga berikut ini ditunjukkan pemodelan menggunakan ANFIS yang terlebih dahulu dilakukan pengujian linieritas. Uji linieritas yang dilakukan menggunakan uji White serta uji Terasvirta agar pengujian lebih akurat dalam menunjukkan hasil pengujian. Adapun pengujian linieritas yang digunakan untuk yang dilakukan dengan menggunakan informasi dari lag 1 dari variabel dependen jumlah penumpang sesuai *default* pada *R Software*.

Tabel 4.14 Hasil Uji Linieritas

Uji	X^2_{hitung}	db	$X^2_{(1-0.05),db}$	p-value
Terasvirta	10.0616	2	5.9915	0.006534
White	11.4871	2	5.9915	0.003203

Uji linieritas menggunakan kedua metode Terasvirta dan White menunjukkan derajat bebas sejumlah dua yang diperoleh dari adanya m prediktor tambahan dalam pengujian. Adapun prediktor yang digunakan adalah sejumlah $m=2$ yang terdiri dari suku kuadratik dan kubik. Statistik uji *chi square* dari kedua pengujian terasvirta dan white menunjukkan nilai yang lebih besar dari pada $X^2_{(1-0.05),db}$ serta hasil pengujian juga dapat ditandai dengan adanya *p-value* yang lebih kecil dari $\alpha=0.05$. Keduanya menunjukkan bahwa data jumlah penumpang adalah nonlinier. Pemodelan dilanjutkan pada pemodelan ANFIS karena untuk menemukan model terbaik.

Langkah awal untuk pemodelan ANFIS adalah dengan menentukan variabel *input*. Beberapa variabel *input* dapat dipilih dalam penelitian ini didasarkan pada orde p yang signifikan dalam prosedur signifikansi parameter serta pada pemodelan ARIMA. Berikut ini ditampilkan kombinasi *input* yang dapat dihasilkan dari penjabaran model ARIMA ([4,6],1,1)(0,1,1)⁷.

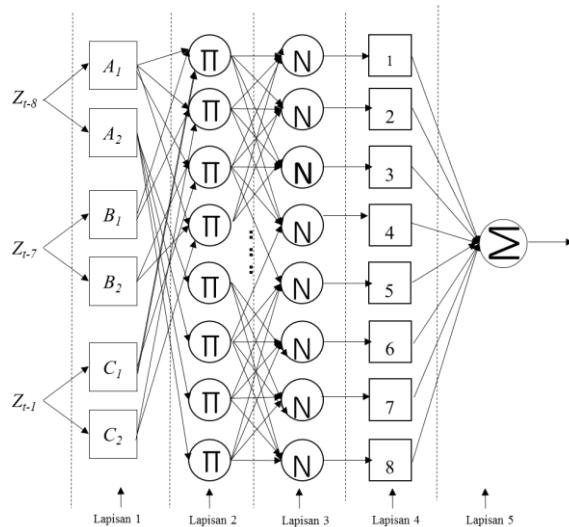
Tabel 4.15 Kombinasi Variabel *Input*

Pemilihan	Kode <i>Input</i>	Kombinasi Variabel <i>Input</i>
([4,6],1,1)(0,1,1) ⁷	1	$Z_{t-8}, Z_{t-7}, Z_{t-1}$
	2	Z_{t-7}, Z_{t-1}
	3	Z_{t-8}, Z_{t-7}
	4	$Z_{t-7}, Z_{t-4}, Z_{t-1}$
	5	$Z_{t-7}, Z_{t-6}, Z_{t-1}$
	6	Z_{t-7}, Z_{t-4}
	7	Z_{t-7}, Z_{t-6}

Kombinasi variabel *input* yang digunakan berasal dari pemodelan ARIMA ([4,6],1,1)(0,1,1)⁷ yang dijabarkan kemudian mencari kombinasi *input* yang dapat memberi akurasi yang tinggi. Setelah proses pemilihan variabel *input*, maka prosedur selanjutnya adalah penentuan jumlah fungsi keanggotaan dan jenis fungsi keanggotaan. Jumlah fungsi keanggotaan yang digunakan adalah sebanyak dua fungsi keanggotaan sedangkan jenis fungsi keanggotaan yang digunakan adalah bentuk kurva *Gaussian*, *generalized bell*, *trapezoidal*, *triangular*, dan *pi* karena kelima jenis fungsi keanggotaan memiliki bentuk kurva yang hampir sama. Pemodelan ANFIS memiliki proses yang iteratif sehingga dalam hal ini digunakan jumlah *epoch* yang disesuaikan yaitu 500 *epoch*. Jumlah *epoch* ditentukan sebanyak 500 karena telah dianggap memberikan hasil akurasi yang baik pada model. Setelah langkah awal telah ditentukan, maka selanjutnya adalah pemodelan ANFIS di mana arsitektur ANFIS terdiri dari lima lapisan yang memproses suatu *output*. Penjelasan detail hanya diberikan untuk jenis *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$ yang diterapkan pada ketiga jenis fungsi keanggotaan. Arsitektur ANFIS dengan tiga *input* ditunjukkan oleh Gambar 4.10.

Arsitektur ANFIS untuk jenis *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$ dapat ditunjukkan oleh Gambar 4.10. Jenis *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$ masing-masing memiliki dua fungsi keanggotaan sehingga pada lapisan ke-2 terdapat delapan node bersimbolkan π yang merepre-

sentasikan adanya delapan aturan yang terbentuk dari jumlah input yang digunakan dan jumlah fungsi keanggotaan.



Gambar 4.10 Arsitektur ANFIS dengan Tiga *Input* dan Delapan Aturan
(Garis hubungan dari *input* ke lapisan ke-4 tidak ditunjukkan)

4.3.1 Proses pada Lapisan ke-1 Arsitektur ANFIS

Lapisan ke-1 merupakan lapisan yang memproses suatu himpunan bilangan klasik menjadi himpunan *fuzzy*. Jenis *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$ pada data *in-sample* dan target untuk *in-sample* yang diterapkan pada pemodelan ANFIS antara lain ditunjukkan oleh Tabel 4.16 berikut ini.

Tabel 4.16 Input Data *In-sample*

Data ke-	Z_{t-8}	Z_{t-7}	Z_{t-1}	Target Output (Z_t)
1	1019	1004	954	1007
2	1004	977	1007	982

Tabel 4.16 Input Data *In-sample* (Lanjutan)

Data ke-	Z_{t-8}	Z_{t-7}	Z_{t-1}	Target <i>Output</i> (Z_t)
3	977	1160	982	1116
:	:	:	:	:
348	906	925	907	923
349	925	933	923	922

Lapisan ke-1 menghasilkan parameter nonlinier untuk setiap lima fungsi keanggotaan atau bisa disebut parameter *premise* yang digunakan untuk mengubah bilangan klasik menjadi bilangan *fuzzy*. Proses adaptasi terjadi pada lapisan ini sesuai dengan parameter yang dihasilkan. Parameter nonlinier yang telah mengalami perbaikan ditunjukkan oleh Tabel 4.17 hingga 4.21.

Tabel 4.17 Parameter Nonlinier Fungsi Keanggotaan *Gaussian*

<i>Input</i>	σ	c
<i>Input1</i> mf1 (A1)	220.20	847.70
<i>Input1</i> mf2 (A2)	151.40	1141.00
<i>Input2</i> mf1 (B1)	31.84	840.40
<i>Input2</i> mf2 (B2)	46.32	1255.00
<i>Input3</i> mf1 (C1)	101.20	903.90
<i>Input3</i> mf2 (C2)	182.00	1235.00

Tabel 4.18 Parameter Nonlinier Fungsi Keanggotaan *Generalized bell*

<i>Input</i>	a	b	c
<i>Input1</i> mf1 (A1)	178.7	0.5456	883.7
<i>Input1</i> mf2 (A2)	181.4	1.9370	1240.0
<i>Input2</i> mf1 (B1)	178.9	-0.5485	883.4
<i>Input2</i> mf2 (B2)	182.0	6.2020	1239.0
<i>Input3</i> mf1 (C1)	176.2	3.9520	881.3
<i>Input3</i> mf2 (C2)	179.7	1.2960	1241.0

Tabel 4.19 Parameter Nonlinier Fungsi Keanggotaan *Trapezoidal*

<i>Input</i>	<i>a</i>	<i>b</i>	<i>c</i>	<i>d</i>
<i>Input1</i> mf1 (A1)	633.40	776.60	978.40	1123
<i>Input1</i> mf2 (A2)	989.00	1121.00	1349.00	1493
<i>Input2</i> mf1 (B1)	633.40	776.60	987.00	1120
<i>Input2</i> mf2 (B2)	991.10	1130.00	1349.00	1493
<i>Input3</i> mf1 (C1)	633.40	776.60	983.00	1124
<i>Input3</i> mf2 (C2)	1026.00	1123.00	1349.00	1493

Tabel 4.20 Parameter Nonlinier Fungsi Keanggotaan *Triangular*

<i>Input</i>	<i>a</i>	<i>b</i>	<i>c</i>
<i>Input1</i> mf1 (A1)	526.0	884	1242
<i>Input1</i> mf2 (A2)	884.0	1242	1600
<i>Input2</i> mf1 (B1)	526.0	884	1242
<i>Input2</i> mf2 (B2)	884.0	1242	1600
<i>Input3</i> mf1 (C1)	526.0	884	1242
<i>Input3</i> mf2 (C2)	884.1	1242	1600

Tabel 4.21 Parameter Nonlinier Fungsi Keanggotaan *Pi*

<i>Input</i>	<i>a</i>	<i>b</i>	<i>c</i>	<i>d</i>
<i>Input1</i> mf1 (A1)	633.4	776.6	1044.0	1045.0
<i>Input1</i> mf2 (A2)	997.6	1150.0	1349.0	1493.0
<i>Input2</i> mf1 (B1)	633.4	776.6	1076.0	1088.0
<i>Input2</i> mf2 (B2)	985.0	1179.0	1349.0	1493.0
<i>Input3</i> mf1 (C1)	633.4	776.6	938.6	1130.0
<i>Input3</i> mf2 (C2)	1038.0	1039.0	1349.0	1493.0

Parameter yang dapat dihasilkan dari proses alur mundur merupakan parameter yang telah optimal memberikan error yang paling kecil dan parameter *premise*/ nonlinier tersebut masing-masing berbeda sesuai dengan lima fungsi keanggotaan yang digunakan.

nakan. Adapun parameter tersebut dapat digunakan untuk menentukan derajat keanggotaan dari tiga *input* yang digunakan memiliki masing-masing sejumlah dua fungsi keanggotaan sehingga dihasilkan sebanyak enam kelompok derajat keanggotaan. Berikut ini persamaan untuk menghitung derajat keanggotan.

1. Persamaan Fungsi Keanggotaan *Gaussian*

Fungsi keanggotaan *Gaussian* memiliki dua parameter non-linier sehingga persamaan Fungsi Keanggotaan *Gaussian* adalah:

$$\mu_{A1}(Z_{t-8}) = \exp\left(\frac{-0.5(Z_{t-8} - 847.7)^2}{(220.2)^2}\right); \quad \mu_{A2}(Z_{t-8}) = \exp\left(\frac{-0.5(Z_{t-8} - 1141)^2}{(151.40)^2}\right)$$

$$\mu_{B1}(Z_{t-7}) = \exp\left(\frac{-0.5(Z_{t-7} - 840.4)^2}{(31.84)^2}\right); \quad \mu_{B2}(Z_{t-7}) = \exp\left(\frac{-0.5(Z_{t-7} - 1255)^2}{(46.32)^2}\right)$$

$$\mu_{C1}(Z_{t-1}) = \exp\left(\frac{-0.5(Z_{t-1} - 903.9)^2}{(101.2)^2}\right); \quad \mu_{C2}(Z_{t-1}) = \exp\left(\frac{-0.5(Z_{t-1} - 1235)^2}{(182)^2}\right)$$

2. Persamaan Fungsi Keanggotaan *Generalized bell*

Berikut ini merupakan fungsi keanggotaan *generalized bell* berdasarkan tiga parameter nonlinier.

$$\mu_{A1}(Z_{t-8}) = \frac{1}{1 + \left| \frac{Z_{t-8} - 883.7}{178.7} \right|^{2(0.5456)}}; \quad \mu_{A2}(Z_{t-8}) = \frac{1}{1 + \left| \frac{Z_{t-8} - 1240}{181.4} \right|^{2(1.937)}}$$

$$\mu_{B1}(Z_{t-7}) = \frac{1}{1 + \left| \frac{Z_{t-7} - 883.4}{178.9} \right|^{2(-0.5485)}}; \quad \mu_{B2}(Z_{t-7}) = \frac{1}{1 + \left| \frac{Z_{t-7} - 1239}{182} \right|^{2(6.202)}}$$

$$\mu_{C1}(Z_{t-1}) = \frac{1}{1 + \left| \frac{Z_{t-1} - 881.3}{176.2} \right|^{2(3.952)}}; \quad \mu_{C2}(Z_{t-1}) = \frac{1}{1 + \left| \frac{Z_{t-1} - 1241}{179.7} \right|^{2(1.296)}}$$

3. Persamaan Fungsi Keanggotaan *Trapezoidal*

Berbeda dengan dua fungsi keanggotaan sebelumnya yaitu fungsi keanggotaan *Gaussian* dan *generalized bell*, fungsi keanggotaan *trapezoidal* memiliki empat jenis parameter nonlinier yang dapat membuat bentuk kurva berubah, sehingga persamaan untuk menghitung derajat keanggotaan dapat ditunjukkan berikut ini.

$$\mu_{A1}(Z_{t-8}) = \begin{cases} 0, & Z_{t-8} \leq 633.4 \\ (Z_{t-8} - 633.4)/(776.6 - 633.4), & 633.4 \leq Z_{t-8} \leq 776.6 \\ 1, & 776.6 \leq Z_{t-8} \leq 978.4 \\ (1123 - Z_{t-8})/(1123 - 978.4), & 978.4 \leq Z_{t-8} \leq 1123 \\ 0, & 1123 \leq Z_{t-8} \end{cases}$$

$$\mu_{A2}(Z_{t-8}) = \begin{cases} 0, & Z_{t-8} \leq 989 \\ (Z_{t-8} - 989)/(1121 - 989), & 989 \leq Z_{t-8} \leq 1121 \\ 1, & 1121 \leq Z_{t-8} \leq 1349 \\ (1493 - Z_{t-8})/(1492 - 1349), & 1349 \leq Z_{t-8} \leq 1493 \\ 0, & 1493 \leq Z_{t-8} \end{cases}$$

$$\mu_{B1}(Z_{t-7}) = \begin{cases} 0, & Z_{t-7} \leq 633.4 \\ (Z(x_{t-7} - 633.4)/(776.6 - 633.4), & 633.4 \leq Z_{t-7} \leq 776.6 \\ 1, & 776.6 \leq Z_{t-7} \leq 987 \\ (1120 - Z_{t-7})/(1120 - 987), & 987 \leq Z_{t-7} \leq 1120 \\ 0, & 1120 \leq Z_{t-7} \end{cases}$$

$$\mu_{B2}(Z_{t-7}) = \begin{cases} 0, & Z_{t-7} \leq 991.1 \\ (Z_{t-7} - 991.1)/(1130 - 991.1), & 991.1 \leq Z_{t-7} \leq 1130 \\ 1, & 1130 \leq Z_{t-7} \leq 1349 \\ (1493 - Z_{t-7})/(1492 - 1349), & 1349 \leq Z_{t-7} \leq 1493 \\ 0, & 1493 \leq Z_{t-7} \end{cases}$$

$$\mu_{C1}(Z_{t-1}) = \begin{cases} 0, & Z_{t-1} \leq 633.4 \\ (Z_{t-1} - 633.4)/(776.6 - 633.4), & 633.4 \leq Z_{t-1} \leq 776.6 \\ 1, & 776.6 \leq Z_{t-1} \leq 983 \\ (1124 - Z_{t-1})/(1124 - 983), & 983 \leq Z_{t-1} \leq 1124 \\ 0, & 1124 \leq Z_{t-1} \end{cases}$$

$$\mu_{C2}(Z_{t-1}) = \begin{cases} 0, & Z_{t-1} \leq 1026 \\ (Z_{t-1} - 1026)/(1123 - 1026), & 1026 \leq Z_{t-1} \leq 1123 \\ 1, & 1123 \leq Z_{t-1} \leq 1349 \\ (1493 - Z_{t-1})/(1493 - 1349), & 1349 \leq Z_{t-1} \leq 1493 \\ 0, & 1493 \leq Z_{t-1} \end{cases}.$$

4. Persamaan Fungsi Keanggotaan *Triangular*

Fungsi keanggotaan *triangular* memiliki memiliki tiga jenis parameter nonlinier sehingga persamaan yang didapatkan adalah sebagai berikut ini.

$$\mu_{A1}(Z_{t-8}) = \begin{cases} 0, & Z_{t-8} \leq 526. \\ (Z_{t-8} - 526)/(884 - 526), & 526 \leq Z_{t-8} \leq 884. \\ (1242 - Z_{t-8})/(1242 - 884), & 884 \leq Z_{t-8} \leq 1242. \\ 0 & 1242 \leq Z_{t-8}. \end{cases}$$

$$\mu_{A2}(Z_{t-8}) = \begin{cases} 0, & Z_{t-8} \leq 884. \\ (Z_{t-8} - 884)/(1242 - 884), & 884 \leq Z_{t-8} \leq 1242. \\ (1600 - Z_{t-8})/(1600 - 1242), & 1242 \leq Z_{t-8} \leq 1600. \\ 0 & 1600 \leq Z_{t-8}. \end{cases}$$

$$\mu_{B1}(Z_{t-7}) = \begin{cases} 0, & Z_{t-7} \leq 526 \\ (Z_{t-7} - 526)/(884 - 526), & 526 \leq Z_{t-7} \leq 884 \\ (1242 - Z_{t-7})/(1242 - 884), & 884 \leq Z_{t-7} \leq 1242 \\ 0, & 1242 \leq Z_{t-7} \end{cases}$$

$$\mu_{B2}(Z_{t-7}) = \begin{cases} 0, & Z_{t-7} \leq 884 \\ (Z_{t-7} - 884)/(1242 - 884), & 884 \leq Z_{t-7} \leq 1242 \\ (1600 - Z_{t-7})/(1600 - 1242), & 1242 \leq Z_{t-7} \leq 1600 \\ 0, & 1600 \leq Z_{t-7} \end{cases}$$

$$\mu_{C1}(Z_{t-1}) = \begin{cases} 0, & Z_{t-1} \leq 526 \\ (Z_{t-1} - 526)/(884 - 526), & 526 \leq Z_{t-1} \leq 884 \\ (1242 - Z_{t-1})/(1242 - 884), & 884 \leq Z_{t-1} \leq 1242 \\ 0, & 1242 \leq Z_{t-1} \end{cases}$$

$$\mu_{C2}(Z_{t-1}) = \begin{cases} 0, & Z_{t-1} \leq 884.1 \\ (Z_{t-1} - 884.1)/(1242 - 884.1), & 884.1 \leq Z_{t-1} \leq 1242 \\ (1600 - Z_{t-1})/(1600 - 1242), & 1242 \leq Z_{t-1} \leq 1600 \\ 0, & 1600 \leq Z_{t-1} \end{cases}$$

5. Persamaan Fungsi Keanggotaan *Pi*

Sama halnya dengan fungsi keanggotaan *trapezoidal*, fungsi keanggotaan bentuk kurva *pi* juga memiliki empat jenis parameter nonlinier dalam fungsi keanggotaan. Namun, kedua fungsi keanggotaan *trapezoidal* dan *pi* memiliki perbedaan pada bentuk kurva yang dihasilkan berdasarkan bentuk puncaknya, adapun derajat keanggotaan yang dapat diperoleh untuk membentuk kurva *pi* dihasilkan dari persamaan berikut ini.

$$\mu_{A_i}(Z_{t-8}) = \begin{cases} 0, & Z_{t-8} \leq 633.4 \\ 2((Z_{t-8} - 633.4)/((776.6 - 633.4))^2, & 633.4 \leq Z_{t-8} \leq (633.4 + 776.6)/2 \\ 1 - 2((Z_{t-8} - 776.6)/((776.6 - 633.4))^2, & (633.4 + 776.6)/2 \leq Z_{t-8} \leq 776.6 \\ 1, & 776.6 \leq Z_{t-8} \leq 1044 \\ 1 - 2((Z_{t-8} - 1044)/((1045 - 1044))^2, & 1044 \leq Z_{t-8} \leq (1044 + 1045)/2 \\ 2((Z_{t-8} - 1045)/((1045 - 1044))^2, & (1044 + 1045)/2 \leq Z_{t-8} \leq 1045 \\ 0, & Z_{t-8} \geq 1045 \end{cases}$$

$$\mu_{A_2}(Z_{t-8}) = \begin{cases} 0, & Z_{t-8} \leq 997.6 \\ 2((Z_{t-8} - 997.6)/(1150 - 997.6))^2, & 997.6 \leq Z_{t-8} \leq (997.6 + 1150)/2 \\ 1 - 2((Z_{t-8} - 1150)/(1150 - 997.6))^2, & (997.6 + 1150)/2 \leq Z_{t-8} \leq 1150 \\ 1, & 1150 \leq Z_{t-8} \leq 1349 \\ 1 - 2((Z_{t-8} - 1349)/(1493 - 1349))^2, & 1349 \leq Z_{t-8} \leq (1349 + 1493)/2 \\ 2((Z_{t-8} - 1493)/(1493 - 1349))^2, & (1349 + 1493)/2 \leq Z_{t-8} \leq 1493 \\ 0, & Z_{t-8} \geq 1493 \end{cases}$$

$$\mu_{B_1}(Z_{t-7}) = \begin{cases} 0, & Z_{t-7} \leq 633.4 \\ 2((Z_{t-7} - 633.4)/(776.6 - 633.4))^2, & 633.4 \leq Z_{t-7} \leq (633.4 + 776.6)/2 \\ 1 - 2((Z_{t-7} - 776.6)/(776.6 - 633.4))^2, & (633.4 + 776.6)/2 \leq Z_{t-7} \leq 776.6 \\ 1, & 776.6 \leq Z_{t-7} \leq 1076 \\ 1 - 2((Z_{t-7} - 1076)/(1088 - 1076))^2, & 1076 \leq Z_{t-7} \leq (1076 + 1088)/2 \\ 2((Z_{t-7} - 1088)/(1088 - 1076))^2, & (1076 + 1088)/2 \leq Z_{t-7} \leq 1088 \\ 0, & Z_{t-7} \geq 1088 \end{cases}$$

$$\mu_{B_2}(Z_{t-7}) = \begin{cases} 0, & Z_{t-7} \leq 985 \\ 2((Z_{t-7} - 985)/(1179 - 985))^2, & 985 \leq Z_{t-7} \leq (985 + 1179)/2 \\ 1 - 2((Z_{t-7} - 1179)/(1179 - 985))^2, & (985 + 1179)/2 \leq Z_{t-7} \leq 1179 \\ 1, & 1179 \leq Z_{t-7} \leq 1349 \\ 1 - 2((Z_{t-7} - 1349)/(1493 - 1349))^2, & 1349 \leq Z_{t-7} \leq (1349 + 1493)/2 \\ 2((Z_{t-7} - 1493)/(1493 - 1349))^2, & (1349 + 1493)/2 \leq Z_{t-7} \leq 1493 \\ 0, & Z_{t-7} \geq 1493 \end{cases}$$

$$\mu_{C_1}(Z_{t-1}) = \begin{cases} 0, & Z_{t-1} \leq 633.4 \\ 2((Z_{t-1} - 633.4)/(776.6 - 633.4))^2, & 633.4 \leq Z_{t-1} \leq (633.4 + 776.6)/2 \\ 1 - 2((Z_{t-1} - 776.6)/(776.6 - 633.4))^2, & (633.4 + 776.6)/2 \leq Z_{t-1} \leq 776.6 \\ 1, & 776.6 \leq Z_{t-1} \leq 938.6 \\ 1 - 2((Z_{t-1} - 938.6)/(1130 - 938.6))^2, & 938.6 \leq Z_{t-1} \leq (938.6 + 1130)/2 \\ 2((Z_{t-1} - 1130)/(1130 - 938.6))^2, & (938.6 + 1130)/2 \leq Z_{t-1} \leq 1130 \\ 0, & Z_{t-1} \geq 1130 \end{cases}$$

$$\mu_{B_2}(Z_{t-1}) = \begin{cases} 0, & Z_{t-1} \leq 1038 \\ 2((Z_{t-1} - 1038)/(1039 - 1038))^2, & 1038 \leq Z_{t-1} \leq (1038 + 1039)/2 \\ 1 - 2((Z_{t-1} - 1039)/(1039 - 1038))^2, & (1038 + 1039)/2 \leq Z_{t-1} \leq 1179 \\ 1, & 1039 \leq Z_{t-1} \leq 1349 \\ 1 - 2((Z_{t-1} - 1349)/(1493 - 1349))^2, & 1349 \leq Z_{t-1} \leq (1349 + 1493)/2 \\ 2((Z_{t-1} - 1493)/(1493 - 1349))^2, & (1349 + 1493)/2 \leq Z_{t-1} \leq 1493 \\ 0, & Z_{t-1} \geq 1493 \end{cases}$$

Berdasarkan arsitektur ANFIS pada Gambar 4.10 diketahui bahwa pada lapisan ke-1 terdiri dari dua node untuk setiap *input* terdiri dari $Z_{t-8}, Z_{t-7}, Z_{t-1}$ sehingga terdapat enam node pada lapisan ke-1. Node tersebut adaptif terhadap parameter nonlinier dari setiap fungsi keanggotaan. Adapun persamaan yang telah dijabarkan dari masing-masing fungsi keanggotaan dan parameter nonlinier digunakan untuk menghitung suatu derajat keanggotaan untuk data ke-1 sampai dengan 349. *Output* atau hasil masing-masing untuk kelima jenis fungsi keanggotaan dari lapisan ke-1 yang merupakan himpunan bilangan *fuzzy* ditunjukkan oleh Tabel 4.22 hingga Tabel 4.25 berikut ini. Adapun derajat keanggotaan yang dihasilkan berupa nilai dari nol sampai dengan satu.

Tabel 4.22 *Output* Lapisan ke-1 pada Pemodelan ANFIS
Fungsi Keanggotaan *Gaussian*

Data ke-	Derajat Keanggotaan					
	μ_{A1}	μ_{A2}	μ_{B1}	μ_{B2}	μ_{C1}	μ_{C2}
1	0.7389	0.7228	1.850E-06	4.205E-07	0.8847	0.3036
2	0.7773	0.6640	0.0001	1.507E-08	0.5951	0.4563
3	0.8416	0.5562	1.322E-22	0.1221	0.7425	0.3805
:	:	:	:	:	:	:
348	0.9656	0.2998	0.0293	9.515E-12	0.9995	0.1971
349	0.9402	0.361	0.0146	3.208E-11	0.9823	0.2301

Tabel 4.23 Output Lapisan ke-1 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Generalized bell*

Data ke-	Derajat Keanggotaan					
	μ_{A1}	μ_{A2}	μ_{B1}	μ_{B2}	μ_{C1}	μ_{C2}
1	0.5753	0.3176	0.3935	0.0403	0.9991	0.2291
2	0.6063	0.2652	0.3295	0.0108	0.9352	0.3353
3	0.6702	0.1917	0.6173	1.0000	0.9881	0.2794
:	:	:	:	:	:	:
348	0.9064	0.0859	0.1680	0.0012	1.0000	0.1671
349	0.8318	0.1055	0.1967	0.0016	1.0000	0.1855

Tabel 4.24 Output Lapisan ke-1 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Trapezoidal*

Data ke-	Derajat Keanggotaan					
	μ_{A1}	μ_{A2}	μ_{B1}	μ_{B2}	μ_{C1}	μ_{C2}
1	0.7192	0.2273	0.8722	0.0929	1.0000	0.0000
2	0.8230	0.1136	1.0000	0.0000	0.8298	0.0000
3	1.0000	0.0000	0.0000	1.0000	1.0000	0.0000
:	:	:	:	:	:	:
348	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000
349	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000

Tabel 4.25 Output Lapisan ke-1 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Triangular*

Data ke-	Derajat Keanggotaan					
	μ_{A1}	μ_{A2}	μ_{B1}	μ_{B2}	μ_{C1}	μ_{C2}
1	0.6229	0.3771	0.6648	0.3352	0.8045	0.1953
2	0.6648	0.3352	0.7402	0.2598	0.6564	0.3434
3	0.7402	0.2598	0.2291	0.7709	0.7263	0.2735
:	:	:	:	:	:	:
348	0.9385	0.0615	0.8855	0.1145	0.9358	0.0640

Tabel 4.25 *Output* Lapisan ke-1 pada Pemodelan ANFIS dengan Fungsi Keanggotaan Triangular (Lanjutan)

Data ke-	Derajat Keanggotaan					
	μ_{A1}	μ_{A2}	μ_{B1}	μ_{B2}	μ_{C1}	μ_{C2}
349	0.8855	0.1145	0.8631	0.1369	0.8911	0.1087

Tabel 4.26 *Output* Lapisan ke-1 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Pi*

Data ke-	Derajat Keanggotaan					
	μ_{A1}	μ_{A2}	μ_{B1}	μ_{B2}	μ_{C1}	μ_{C2}
1	1.0000	0.0394	1.0000	0.0192	0.9871	0.0000
2	1.0000	0.0035	1.0000	0.0000	0.7446	0.0000
3	1.0000	0.0000	0.0000	0.9808	0.8972	0.0000
:	:	:	:	:	:	:
348	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000
349	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000

4.3.2 Proses pada Lapisan ke-2 Arsitektur ANFIS

Output yang dihasilkan pada lapisan ke-1 yaitu derajat keanggotaan diproses kembali pada lapisan ke-2. Lapisan ke-2 berdasarkan arsitektur ANFIS pada Gambar 4.10 menunjukkan bahwa terdapat delapan node tetap adapun kedelapan node merepresentasikan perhitungan *the firing strength* atau α -predikat. Adapun perhitungan *the firing strength* adalah dengan mengalikan semua derajat keanggotaan pada lapisan ke-1 dengan memperhatikan *the firing strength of rule* di mana aturan tersebut berasal dari salah satu operator dasar Zadeh yaitu operator/ logika AND. Logika AND mengombinasi dan memodifikasi himpunan fuzzy yang berupa derajat keanggotaan yang telah dihasilkan pada lapisan ke-1.

Berikut ini delapan aturan yang berasal dari jumlah *input* dipangkatkan jumlah fungsi keanggotaan ($2^3=8$)

if Z_{t-8} is A1 and Z_{t-7} is B1 and Z_{t-1} is C1, then w_{1,t}= $\mu_{A1} \mu_{B1} \mu_{C1}$

if Z_{t-8} is A1 and Z_{t-7} is B1 and Z_{t-1} is C2, then $w_{2,t} = \mu_{A1} \mu_{B1} \mu_{C2}$
 if Z_{t-8} is A1 and Z_{t-7} is B2 and Z_{t-1} is C1, then $w_{3,t} = \mu_{A1} \mu_{B2} \mu_{C1}$
 if Z_{t-8} is A1 and Z_{t-7} is B2 and Z_{t-1} is C2, then $w_{4,t} = \mu_{A1} \mu_{B2} \mu_{C2}$
 if Z_{t-8} is A2 and Z_{t-7} is B1 and Z_{t-1} is C1, then $w_{5,t} = \mu_{A2} \mu_{B1} \mu_{C1}$
 if Z_{t-8} is A2 and Z_{t-7} is B1 and Z_{t-1} is C2, then $w_{6,t} = \mu_{A2} \mu_{B1} \mu_{C2}$
 if Z_{t-8} is A2 and Z_{t-7} is B2 and Z_{t-1} is C1, then $w_{7,t} = \mu_{A2} \mu_{B2} \mu_{C1}$
 if Z_{t-8} is A2 and Z_{t-7} is B2 and Z_{t-1} is C2, then $w_{8,t} = \mu_{A2} \mu_{B2} \mu_{C2}$

Kedelapan aturan hasil operator AND tersebut merupakan pedoman untuk perhitungan *firing strength*. Berdasarkan kedelapan aturan tersebut, didapatkan hasil dari lapisan ke-2 yang ditunjukkan oleh Tabel 4.27 sampai dengan 4.31.

Tabel 4.27 Output Lapisan ke-2 pada Pemodelan ANFIS
Fungsi Keanggotaan Gaussian

Data ke-	Firing Strength			
	$w_{1,t}$	$w_{2,t}$	$w_{3,t}$	$w_{4,t}$
1	1.21E-06	4.15E-07	2.75E-07	9.43E-08
2	4.66E-05	3.57E-05	6.97E-09	5.35E-09
3	8.26E-23	4.23E-23	0.0763	0.0391
:	:	:	:	:
348	0.0283	0.0056	9.18E-12	1.81E-12
349	0.0135	0.0032	2.96E-11	6.94E-12

Data ke-	Firing Strength			
	$w_{5,t}$	$w_{6,t}$	$w_{7,t}$	$w_{8,t}$
1	1.18E-06	4.06E-07	2.69E-07	9.23E-08
2	3.98E-05	3.05E-05	5.96E-09	4.57E-09
3	5.46E-23	2.8E-23	0.0504	0.0258
:	:	:	:	:
348	0.0088	0.0017	2.85E-12	5.62E-13
349	0.0052	0.0012	1.14E-11	2.67E-12

Tabel 4.28 Output Lapisan ke-2 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Generalized bell*

Data ke-	<i>Firing Strength</i>			
	$w_{1,t}$	$w_{2,t}$	$w_{3,t}$	$w_{4,t}$
1	0.2262	0.0519	0.0232	0.0053
2	0.1868	0.0670	0.0061	0.0022
3	0.4088	0.1156	0.6622	0.1872
:	:	:	:	:
348	0.1522	0.0254	0.0010	0.0002
349	0.1636	0.0303	0.0013	0.0002
Data ke-	<i>Firing Strength</i>			
	$w_{5,t}$	$w_{6,t}$	$w_{7,t}$	$w_{8,t}$
1	0.1249	0.0286	0.0128	0.0029
2	0.0817	0.0293	0.0027	0.0010
3	0.1169	0.0331	0.1894	0.0536
:	:	:	:	:
348	0.0144	0.0024	9.90E-05	1.65E-05
349	0.0207	0.0038	1.67E-04	3.1E-05

Tabel 4.29 Output Lapisan ke-2 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Trapezoidal*

Data ke-	<i>Firing Strength</i>			
	$w_{1,t}$	$w_{2,t}$	$w_{3,t}$	$w_{4,t}$
1	0.6273	0.0000	0.0668	0.0000
2	0.6829	0.0000	0.0000	0.0000
3	0.0000	0.0000	1.0000	0.0000
:				
348	1.0000	0.0000	0.0000	0.0000
349	1.0000	0.0000	0.0000	0.0000

Tabel 4.29 Output Lapisan ke-2 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Trapezoidal* (Lanjutan)

Data ke-	<i>Firing Strength</i>			
	$w_{5,t}$	$w_{6,t}$	$w_{7,t}$	$w_{8,t}$
1	0.1982	0.0000	0.0211	0.0000
2	0.0943	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.0000	0.0000
:				
348	0.0000	0.0000	0.0000	0.0000
349	0.0000	0.0000	0.0000	0.0000

Tabel 4.30 Output Lapisan ke-2 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Triangular*

Data ke-	<i>Firing Strength</i>			
	$w_{1,t}$	$w_{2,t}$	$w_{3,t}$	$w_{4,t}$
1	0.3331	0.0809	0.1680	0.0408
2	0.3230	0.1690	0.1134	0.0593
3	0.1231	0.0464	0.4145	0.1561
:	:	:	:	:
348	0.7777	0.0532	0.1006	0.0069
349	0.6810	0.0831	0.1080	0.0132

Data ke-	<i>Firing Strength</i>			
	$w_{5,t}$	$w_{6,t}$	$w_{7,t}$	$w_{8,t}$
1	0.2017	0.0490	0.1017	0.0247
2	0.1629	0.0852	0.0572	0.0299
3	0.0432	0.0163	0.1455	0.0548
:				
348	0.0509	0.0035	0.0066	0.0005
349	0.0881	0.0107	0.0140	0.0017

Tabel 4.31 *Output* Lapisan ke-2 pada Pemodelan ANFIS dengan Fungsi Keanggotaan P_i

Data ke-	<i>Firing Strength</i>			
	$w_{1,t}$	$w_{2,t}$	$w_{3,t}$	$w_{4,t}$
1	0.9871	0.0000	0.0189	0.0000
2	0.7446	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.8800	0.0000
:	:	:	:	:
348	1.0000	0.0000	0.0000	0.0000
349	1.0000	0.0000	0.0000	0.0000

Data ke-	<i>Firing Strength</i>			
	$w_{5,t}$	$w_{6,t}$	$w_{7,t}$	$w_{8,t}$
1	0.0389	0.0000	0.0007	0.0000
2	0.0026	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.0000	0.0000
:				
348	0.0000	0.0000	0.0000	0.0000
349	0.0000	0.0000	0.0000	0.0000

4.3.3 Proses pada Lapisan ke-3 Arsitektur ANFIS

The *firing strength* yang dihasilkan dari proses pada lapisan ke-2 kemudian menjadi *input* untuk lapisan ke-3. Lapisan ke-3 terdiri dari delapan node tetap sama halnya dengan node pada lapisan ke-2 karena pada kedua lapisan tersebut tidak dihasilkan parameter. Proses pada lapisan ke-3 merupakan proses normalisasi untuk mendapatkan *normalized firing strength*. Perhitungan *normalized firing strength* adalah dengan melakukan pembagian antara $w_{i,t}$ dengan jumlah total dari $w_{i,t}$ dengan $i=1,2,\dots,8$. *Normalized firing strength* ditunjukkan oleh Tabel 4.32 sampai dengan Tabel 4.36 untuk masing-masing fungsi keanggotaan yang digunakan.

Tabel 4.32 Output Lapisan ke-3 pada Pemodelan ANFIS
Fungsi Keanggotaan *Gaussian*

Data ke-	<i>Normalized Firing Strength</i>			
	$\bar{w}_{1,t}$	$\bar{w}_{2,t}$	$\bar{w}_{3,t}$	$\bar{w}_{4,t}$
1	0.3066	0.1052	0.0697	0.0239
2	0.3052	0.2340	4.57E-05	3.5E-05
3	4.31E-22	2.21E-22	0.3981	0.2040
:	:	:	:	:
348	0.6374	0.1257	2.07E-10	4.08E-11
349	0.5853	0.1371	1.29E-09	3.02E-10

Data ke-	<i>Normalized Firing Strength</i>			
	$\bar{w}_{5,t}$	$\bar{w}_{6,t}$	$\bar{w}_{7,t}$	$\bar{w}_{8,t}$
1	0.2999	0.1029	0.0682	0.0234
2	0.2607	0.1999	3.9E-05	2.99E-05
3	2.85E-22	1.46E-22	0.2631	0.1348
:	:	:	:	:
348	0.1979	0.0390	6.42E-11	1.27E-11
349	0.2250	0.0527	4.96E-10	1.16E-10

Tabel 4.33 Output Lapisan ke-3 pada Pemodelan ANFIS
Fungsi Keanggotaan *Generalized bell*

Data ke-	<i>Normalized Firing Strength</i>			
	$\bar{w}_{1,t}$	$\bar{w}_{2,t}$	$\bar{w}_{3,t}$	$\bar{w}_{4,t}$
1	0.4755	0.1090	0.0487	0.0112
2	0.4959	0.1778	0.0162	0.0058
3	0.2314	0.0654	0.3748	0.1060
:	:	:	:	:
348	0.7774	0.1299	0.0053	0.0009
349	0.7426	0.1378	0.0060	0.0011

Tabel 4.33 Output Lapisan ke-3 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Generalized bell* (Lanjutan)

Data ke-	<i>Normalized Firing Strength</i>			
	$\bar{w}_{5,t}$	$\bar{w}_{6,t}$	$\bar{w}_{7,t}$	$\bar{w}_{8,t}$
1	0.2624	0.0602	0.0269	0.0062
2	0.2169	0.0778	0.0071	0.0025
3	0.0662	0.0187	0.1072	0.0303
:	:	:	:	:
348	0.0737	0.0123	5.05E-04	8.44E-05
349	0.0942	0.0175	7.59E-04	1.41E-04

Tabel 4.34 Output Lapisan ke-3 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Trapezoidal*

Data ke-	<i>Normalized Firing Strength</i>			
	$\bar{w}_{1,t}$	$\bar{w}_{2,t}$	$\bar{w}_{3,t}$	$\bar{w}_{4,t}$
1	0.6868	0.0000	0.0731	0.0000
2	0.8787	0.0000	0.0000	0.0000
3	0.0000	0.0000	1.0000	0.0000
:	:	:	:	:
348	1.0000	0.0000	0.0000	0.0000
349	1.0000	0.0000	0.0000	0.0000

Data ke-	<i>Normalized Firing Strength</i>			
	$\bar{w}_{5,t}$	$\bar{w}_{6,t}$	$\bar{w}_{7,t}$	$\bar{w}_{8,t}$
1	0.2170	0.0000	0.0231	0.0000
2	0.1213	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.0000	0.0000
:	:	:	:	:
348	0.0000	0.0000	0.0000	0.0000
349	0.0000	0.0000	0.0000	0.0000

Tabel 4.35 *Output* Lapisan ke-3 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Triangular*

Data ke-	<i>Normalized Firing Strength</i>			
	$\bar{w}_{1,t}$	$\bar{w}_{2,t}$	$\bar{w}_{3,t}$	$\bar{w}_{4,t}$
1	0.3332	0.0809	0.1680	0.0408
2	0.3231	0.1690	0.1134	0.0593
3	0.1232	0.0464	0.4145	0.1561
:	:	:	:	:
348	0.7779	0.0532	0.1006	0.0069
349	0.1232	0.0464	0.4145	0.1561

Data ke-	<i>Normalized Firing Strength</i>			
	$\bar{w}_{5,t}$	$\bar{w}_{6,t}$	$\bar{w}_{7,t}$	$\bar{w}_{8,t}$
1	0.2017	0.0490	0.1017	0.0247
2	0.1629	0.0852	0.0572	0.0299
3	0.0432	0.0163	0.1455	0.0548
:	:	:	:	:
348	0.0509	0.0035	0.0066	0.0005
349	0.0432	0.0163	0.1455	0.0548

Tabel 4.36 *Output* Lapisan ke-3 pada Pemodelan ANFIS dengan Fungsi Keanggotaan *Pi*

Data ke-	<i>Normalized Firing Strength</i>			
	$\bar{w}_{1,t}$	$\bar{w}_{2,t}$	$\bar{w}_{3,t}$	$\bar{w}_{4,t}$
1	0.9440	0.0000	0.0181	0.0000
2	0.9965	0.0000	0.0000	0.0000
3	0.0000	0.0000	1.0000	0.0000
:	:	:	:	:
348	1.0000	0.0000	0.0000	0.0000
349	0.1232	0.0464	0.4145	0.1561

Tabel 4.36 Output Lapisan ke-3 pada Pemodelan ANFIS dengan Fungsi Keanggotaan P_i (lanjutan)

Data ke-	Normalized Firing Strength			
	$\bar{w}_{5,t}$	$\bar{w}_{6,t}$	$\bar{w}_{7,t}$	$\bar{w}_{8,t}$
1	0.0372	0.0000	0.0007	0.0000
2	0.0035	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.0000	0.0000
:	:	:	:	:
348	0.0000	0.0000	0.0000	0.0000
349	0.0000	0.0000	0.0000	0.0000

4.3.4 Proses pada Lapisan ke-4 Arsitektur ANFIS

Sama halnya dengan lapisan ke-1, node yang terdapat pada lapisan ke-4 merupakan node adaptif terhadap parameter-parameter yang dihasilkan yang disebut juga parameter *consequent*. Adapun parameter yang dihasilkan juga disebut sebagai parameter linier ini dihasilkan sesuai dengan jumlah aturan yang digunakan yaitu delapan aturan sehingga terdapat delapan kelompok parameter linier. Parameter linier dalam lapisan ke-4 untuk masing-masing fungsi keanggotaan ditunjukkan oleh Tabel 4.37 sampai dengan Tabel 4.41.

Tabel 4.37 Parameter Linier pada Fungsi Keanggotaan *Gaussian*

Input	p	q	r	s
<i>Output 1mf1</i>	2.1250	1.9520	-2.6260	-470.0
<i>Output 1mf2</i>	-8.0590	-0.7554	-3.0540	12390.0
<i>Output 1mf3</i>	-0.7327	-3.2210	7.2310	-955.7
<i>Output 1mf4</i>	26.4900	6.8620	9.7840	-40490.0
<i>Output 1mf5</i>	1.6600	-2.4690	2.5720	-933.4
<i>Output 1mf6</i>	-2.2410	3.3600	3.0520	-2385.0
<i>Output 1mf7</i>	0.8889	2.4930	-6.6570	2679.0
<i>Output 1mf8</i>	6.7990	-4.7600	-15.7700	12960.0

Tabel 4.38 Parameter Linier pada Fungsi Keanggotaan *Generalized bell*

<i>Input</i>	<i>p</i>	<i>q</i>	<i>r</i>	<i>s</i>
<i>Output 1mf1</i>	0.5470	0.4797	-0.2154	81.19
<i>Output 1mf2</i>	-3.3550	2.3470	-1.8990	4169.00
<i>Output 1mf3</i>	-0.7927	-4.1080	3.0430	3560.00
<i>Output 1mf4</i>	23.3400	9.5510	-0.9893	-30770.00
<i>Output 1mf5</i>	0.5761	-1.6350	0.1709	1824.00
<i>Output 1mf6</i>	-0.7834	1.4780	2.2640	-1890.00
<i>Output 1mf7</i>	2.8330	4.1290	1.9390	-8601.00
<i>Output 1mf8</i>	2.3940	-10.4900	-5.4190	13150.00

Tabel 4.39 Parameter Linier pada Fungsi Keanggotaan *Trapezoidal*

<i>Input</i>	<i>p</i>	<i>q</i>	<i>r</i>	<i>s</i>
<i>Output 1mf1</i>	0.0224	0.4898	0.0844	392.7
<i>Output 1mf2</i>	-2.0380	3.2330	-0.9234	959.6
<i>Output 1mf3</i>	0.1801	-0.4311	1.9060	-504.4
<i>Output 1mf4</i>	16.6400	9.0290	1.1690	-26700.0
<i>Output 1mf5</i>	0.3507	-0.0375	-0.0404	670.7
<i>Output 1mf6</i>	-1.3760	-0.1252	0.6838	1887.0
<i>Output 1mf7</i>	-0.3420	0.5345	-0.0150	724.4
<i>Output 1mf8</i>	8.6940	-11.6200	-23.1700	28350.0

Tabel 4.40 Parameter Linier pada Fungsi Keanggotaan *Triangular*

<i>Input</i>	<i>p</i>	<i>q</i>	<i>r</i>	<i>s</i>
<i>Output 1mf1</i>	-1061.0	353.0	714.9	-5335.0
<i>Output 1mf2</i>	-764.0	-244.4	716.2	3797.0
<i>Output 1mf3</i>	-916.1	350.2	420.4	3794.0
<i>Output 1mf4</i>	-248.5	-235.6	415.9	-2703.0
<i>Output 1mf5</i>	-1061.0	1036.0	451.2	3795.0
<i>Output 1mf6</i>	-761.3	437.6	452.6	-2704.0

Tabel 4.40 Parameter Linier pada Fungsi Keanggotaan *Triangular* (Lanjutan)

<i>Input</i>	<i>p</i>	<i>q</i>	<i>r</i>	<i>s</i>
<i>Output 1mf7</i>	-917.2	1040.0	-168.2	-2702.0
<i>Output 1mf8</i>	-252.4	423.6	-174.0	1923.0

Tabel 4.41 Parameter Linier pada Fungsi Keanggotaan *Pi*

<i>Input</i>	<i>p</i>	<i>q</i>	<i>r</i>	<i>s</i>
<i>Output 1mf1</i>	0.03436	0.5650	0.09353	301.9
<i>Output 1mf2</i>	-1.4570	1.2840	-0.4264	1692.0
<i>Output 1mf3</i>	0.1964	-0.0300	2.4050	-1438.0
<i>Output 1mf4</i>	5.0570	6.2200	-5.8070	-4779.0
<i>Output 1mf5</i>	0.1527	0.1866	0.0480	580.1
<i>Output 1mf6</i>	-0.3428	1.2660	0.2507	-131.4
<i>Output 1mf7</i>	0.0559	0.4698	0.8946	-520.4
<i>Output 1mf8</i>	-3.8780	-2.8540	-19.1800	2.86E+04

Berbeda dengan parameter nonlinier, parameter linier yang dihasilkan pada lapisan ke-4 untuk setiap fungsi keanggotaan memiliki jumlah yang sama yaitu p_i, q_i, r_i, s_i . Proses pada lapisan ke-4 merupakan suatu proses perkalian masing-masing *normalized firing strength* dengan operasi parameter *consequent/ linier* yaitu $\bar{w}_{i,t} f_i$ dengan $i=1,2,3,\dots,8$. Adapun hasil pada lapisan ke-4 ini pada masing-masing fungsi keanggotaan ditunjukkan oleh Tabel 4.42 hingga Tabel 4.46.

Tabel 4.42 *Output* dari Lapisan ke-4 dengan Fungsi Keanggotaan *Gaussian*

Data ke-	$\bar{w}_{1,t} f_1$	$\bar{w}_{2,t} f_2$	$\bar{w}_{3,t} f_3$	$\bar{w}_{4,t} f_4$
1	352.0133	53.2487	136.7814	65.2395
2	282.09	113.5710	0.1116	0.0932
3	5.56E-19	1.4167E-19	673.9355	603.6257
:	:	:	:	:
348	559.0199	203.605305	4.05E-07	-5.18E-08
349	521.5002	193.515344	2.62E-06	-1.67E-07

Tabel 4.42 Output dari Lapisan ke-4 dengan Fungsi Keanggotaan Gaussian (Lanjutan)

Data ke-	$\bar{w}_{5,t} f_5$	$\bar{w}_{6,t} f_6$	$\bar{w}_{7,t} f_7$	$\bar{w}_{8,t} f_8$
1	219.8424	166.4129	-17.9343	1.5110
2	237.5444	344.0446	-0.0272	-0.0223
3	9.975E-20	3.39E-19	-25.7375	-189.4436
:	:	:	:	:
348	122.6082	57.0131	-1.59E-08	5.24E-09
349	151.2887	78.7140	-1.57E-07	2.93E-08

Tabel 4.43 Output dari Lapisan ke-4 dengan Fungsi Keanggotaan Generalized bell

Data ke-	$\bar{w}_{1,t} f_1$	$\bar{w}_{2,t} f_2$	$\bar{w}_{3,t} f_3$	$\bar{w}_{4,t} f_4$
1	434.9062	141.1725	74.5455	18.5215
2	437.4538	210.0258	29.4483	5.8083
3	222.2427	114.4112	377.9935	226.8833
:	:	:	:	:
348	641.4192	204.913326	9.61E+00	-1.50E+00
349	620.7552	207.008744	1.08E+01	-1.31E+00
Data ke-	$\bar{w}_{5,t} f_5$	$\bar{w}_{6,t} f_6$	$\bar{w}_{7,t} f_7$	$\bar{w}_{8,t} f_8$
1	244.7456	57.4960	7.5573	-0.6915
2	211.9057	81.4320	1.6316	-0.3869
3	43.5509	23.9954	92.2611	-60.6536
:	:	:	:	:
348	72.8210	10.1009	-2.31E-01	0.0591
349	93.1364	14.9172	-2.57E-01	0.0811

Tabel 4.44 Output dari Lapisan ke-4 dengan Fungsi Keanggotaan Trapezoidal

Data ke-	$\bar{w}_{1,t} f_1$	$\bar{w}_{2,t} f_2$	$\bar{w}_{3,t} f_3$	$\bar{w}_{4,t} f_4$
1	678.3555	0.0000	77.8533	0.0000
2	859.9419	0.0000	0.0000	0.0000
3	0.0000	0.0000	1043.1737	0.0000
:	:	:	:	:
348	942.583	0.0000	0.0000	0.0000
349	948.2769	0.0000	0.0000	0.0000

Tabel 4.44 Output dari Lapisan ke-4 dengan Fungsi Keanggotaan *Trapezoidal* (Lanjutan)

Data ke-	$\bar{w}_{5,t}f_5$	$\bar{w}_{6,t}f_6$	$\bar{w}_{7,t}f_7$	$\bar{w}_{8,t}f_8$
1	206.5501	0.0000	20.7566	0.0000
2	114.7049	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.0000	0.0000
Data ke-	$\bar{w}_{5,t}f_5$	$\bar{w}_{6,t}f_6$	$\bar{w}_{7,t}f_7$	$\bar{w}_{8,t}f_8$
:	:	:	:	:
348	0.0000	0.0000	0.0000	0.0000
349	0.0000	0.0000	0.0000	0.0000

Tabel 4.45 Hasil dari Lapisan ke-4 dengan Fungsi Keanggotaan *Triangular*

Data ke-	$\bar{w}_{1,t}f_1$	$\bar{w}_{2,t}f_2$	$\bar{w}_{3,t}f_3$	$\bar{w}_{4,t}f_4$
1	-16683.1	-27249.2688	-29745.5396	-3903.3490
2	-1871.88	-47463.6861	-17062.5321	-3770.4634
3	8569.497	-14975.1822	-29917.7881	-17232.4844
:	:	:	:	:
348	6486.125	-14087.7654	-12169.0180	-471.5948
349	300.7215	-12518.9073	-53406.4203	-10695.9107
Data ke-	$\bar{w}_{5,t}f_5$	$\bar{w}_{6,t}f_6$	$\bar{w}_{7,t}f_7$	$\bar{w}_{8,t}f_8$
1	79321.8187	4537.9522	-5454.7745	3768.7360
2	65988.4407	9906.9407	-4394.4988	5439.8250
3	26453.7020	3346.6507	20719.4907	6855.5407
:	:	:	:	:
348	20885.5770	427.8245	-159.6964	68.7619
349	17523.0484	1939.2755	-5243.2003	8625.5269

Tabel 4.46 Output dari Lapisan ke-4 Fungsi Keanggotaan Bentuk *Pi*

Data ke-	$\bar{w}_{1,t}f_1$	$\bar{w}_{2,t}f_2$	$\bar{w}_{3,t}f_3$	$\bar{w}_{4,t}f_4$
1	937.7224	0.0000	18.5861	0.0000
2	979.1336	0.0000	0.0000	0.0000
3	0.0000	0.0000	1080.7812	0.0000
:	:	:	:	:

Tabel 4.46 Hasil dari Lapisan ke-4 dengan Fungsi Keanggotaan Bentuk P_i (Lanjutan)

Data ke-	$\bar{w}_{1,t}f_1$	$\bar{w}_{2,t}f_2$	$\bar{w}_{3,t}f_3$	$\bar{w}_{4,t}f_4$
348	940.4869	0.0000	0.0000	0.0000
349	947.1562	0.0000	0.0000	0.0000
Data ke-	$\bar{w}_{5,t}f_5$	$\bar{w}_{6,t}f_6$	$\bar{w}_{7,t}f_7$	$\bar{w}_{8,t}f_8$
1	36.0664	0.0000	0.6154	0.0000
2	3.3885	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.0000	0.0000
:	:	:	:	:
348	0.0000	0.0000	0.0000	0.0000
349	0.0000	0.0000	0.0000	0.0000

4.3.5 Proses pada Lapisan ke-5 Arsitektur ANFIS

Lapisan ke-5 merupakan lapisan yang terakhir dalam pemodelan ANFIS untuk data jumlah penumpang. Lapisan ke-5 memproses *output* yang dihasilkan pada lapisan ke-4 yaitu dengan cara menjumlahkan keseluruhan *output* pada lapisan ke-4. Berikut ini ditunjukkan *output* secara matematis pada lapisan ke-5.

$$\begin{aligned}
 \hat{Z}_t &= \bar{w}_{1,t}f_1 + \bar{w}_{2,t}f_2 + \bar{w}_{3,t}f_3 + \bar{w}_{4,t}f_4 + \bar{w}_{5,t}f_5 + \bar{w}_{6,t}f_6 + \bar{w}_{7,t}f_7 + \bar{w}_{8,t}f_8 \\
 &= \bar{w}_{1,t}(p_1Z_{t-8} + q_1Z_{t-7} + r_1Z_{t-1} + s_1) + \bar{w}_{2,t}(p_2Z_{t-8} + q_2Z_{t-7} + r_2Z_{t-1} + s_2) \\
 &\quad + \bar{w}_{3,t}(p_3Z_{t-8} + q_3Z_{t-7} + r_3Z_{t-1} + s_3) + \bar{w}_{4,t}(p_4Z_{t-8} + q_4Z_{t-7} + r_4Z_{t-1} + s_4) \\
 &\quad + \bar{w}_{5,t}(p_5Z_{t-8} + q_5Z_{t-7} + r_5Z_{t-1} + s_5) + \bar{w}_{6,t}(p_6Z_{t-8} + q_6Z_{t-7} + r_6Z_{t-1} + s_6) \\
 &\quad + \bar{w}_{7,t}(p_7Z_{t-8} + q_7Z_{t-7} + r_7Z_{t-1} + s_7) + \bar{w}_{8,t}(p_8Z_{t-8} + q_8Z_{t-7} + r_8Z_{t-1} + s_8)
 \end{aligned}$$

Sehingga hasil yang diperoleh pada lapisan ke-5 untuk masing-masing keanggotaan merupakan peramalan yang dilakukan oleh pemodelan ANFIS pada data *in-sample* sebanyak 349. Peramalan tidak hanya dilakukan pada data *in-sample* tetapi juga dilakukan untuk *out-sample* sebanyak 14 periode ke depan. Berikut ini merupakan peramalan *in-sample* yang di-proses dari lapisan ke-1 hingga ke-5.

Tabel 4.47 Output dari Lapisan ke-5

<i>t</i>	<i>Z_t</i>				
	Gaussian	Generalized bell	Trapezoidal	Triangular	Pi
1	977	978	984	989	993
2	977	977	975	986	983
3	1062	1041	1043	1076	1081
:	:	:	:	:	:
348	942	937	943	924	940
349	945	945	948	942	947

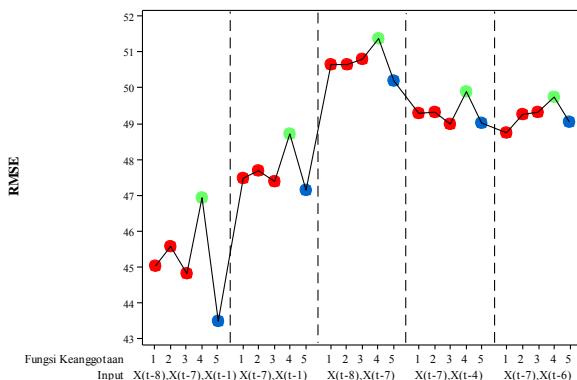
4.3.6 Perbandingan Pemodelan ANFIS

Pemodelan ANFIS dilakukan sebanyak 35 kali yang didasarkan pada empat jenis fungsi keanggotaan yaitu *Gaussian*, *Generalized bell*, *Trapezoidal*, dan *Triangular* serta tujuh jenis input. Namun dalam pemodelan *input Z_{t-7}, Z_{t-4}, Z_{t-1} dan Z_{t-7}, Z_{t-6}, Z_{t-1}* tidak dapat diterapkan pada pemodelan karena terdapat beberapa *input* berada diluar batas spesifikasi sehingga pemodelan ANFIS dilakukan sebanyak 25 kali. Adapun untuk melakukan pemilihan model terbaik digunakan kriteria MAPE dan RMSE yang diterapkan pada data *out-sample*, sedangkan RMSE untuk *in-sample* juga diperhatikan untuk mengetahui bagaimana kecenderungan model ANFIS berdasarkan fungsi keanggotaan dan jenis *input* dalam peramalan. Berikut ini merupakan perbandingan RMSE antar model ANFIS dalam meramalkan *in-sample*.

Tabel 4.48 Perbandingan RMSE Kebaikan Model untuk *In-sample*

Jenis Input	Gauss	Gbell	Trap	Tri	Pi
<i>Z_{t-8}, Z_{t-7}, Z_{t-1}</i>	45.057	45.592	44.838	46.933	43.492
<i>Z_{t-7}, Z_{t-1}</i>	47.496	47.696	47.409	48.706	47.150
<i>Z_{t-8}, Z_{t-7}</i>	50.648	50.643	50.798	51.368	50.192
<i>Z_{t-7}, Z_{t-4},</i>	49.280	49.312	49.001	49.909	49.008
<i>Z_{t-7}, Z_{t-6},</i>	48.741	49.255	49.321	49.756	49.059

Berdasarkan RMSE, *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$ cenderung memberikan nilai RMSE yang kecil dibandingkan keempat jenis *input* lainnya pada masing-masing fungsi keanggotaan. Kriteria RMSE terkecil berturut-turut adalah 45.057, 44.838, dan 43.492 di mana merupakan hasil dari jenis *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$ yang diterapkan pada fungsi keanggotaan *Gaussian*, *trapezoidal*, dan *Pi*. Visualisasi RMSE berdasarkan jenis input dan fungsi keanggotaan dapat ditunjukkan oleh plot individual RMSE pada Gambar 4.11 berikut ini.



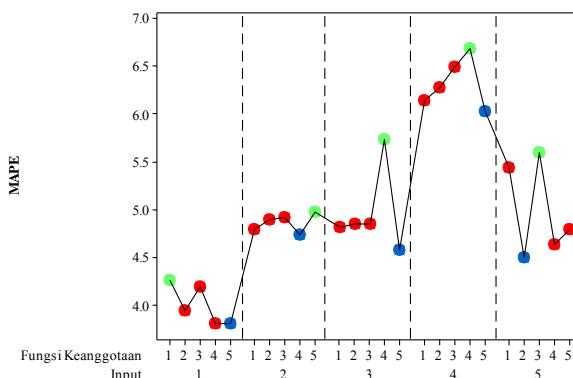
Gambar 4.11 Plot Individual RMSE *In-Sample* Berdasarkan Fungsi Keanggotaan: (1) Gauss, (2) Gbell, (3) Trap, (4) Tri, (5) Pi

RMSE untuk data *In-sample* secara visual memiliki nilai terkecil untuk *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$ sedangkan nilai paling besar dimiliki oleh jenis *input* Z_{t-8}, Z_{t-7} . Berdasarkan jenis fungsi keanggotaan, fungsi keanggotaan *Pi* cenderung memberikan nilai RMSE terkecil sedangkan fungsi keanggotaan *Triangular* cenderung memberikan RMSE yang terbesar pada setiap jenis *input*. Selain itu, perlu untuk mengetahui kriteria kebaikan berdasarkan kriteria dari data *out-sample* karena tujuan dari pemodelan ini adalah untuk meramalkan nilai masa mendatang. Berikut ini merupakan perbandingan RMSE dan MAPE dari *out-sample* yang ditunjukkan oleh Tabel 4.49.

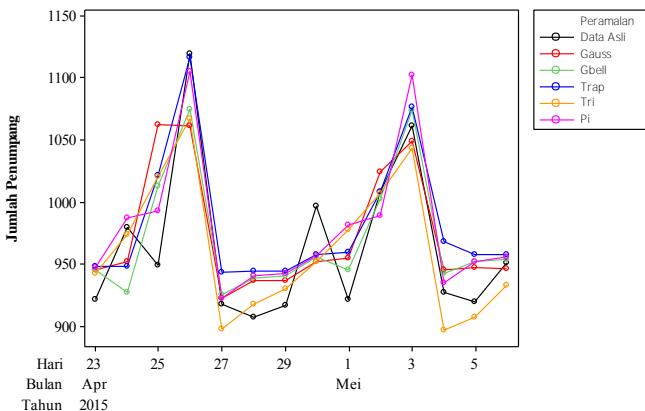
Tabel 4.49 Perbandingan Kriteria Kebaikan Model untuk *Out-sample*

Jenis Input	kriteria	Gauss	Gbell	Trap	Tri	Pi
$Z_{t-8}, Z_{t-7}, Z_{t-1}$	MAPE	4.27	3.94	4.19	3.81	3.81
	RMSE	57.04	52.18	53.64	51.90	51.30
Z_{t-7}, Z_{t-1}	MAPE	4.79	4.89	4.91	4.74	4.98
	RMSE	59.06	58.77	59.53	58.46	60.21
Z_{t-8}, Z_{t-7}	MAPE	4.81	4.85	4.85	5.74	4.58
	RMSE	58.35	58.04	58.59	66.21	57.80
Z_{t-7}, Z_{t-6}	MAPE	6.14	6.28	6.49	6.68	6.03
	RMSE	75.60	78.67	82.22	88.59	76.74
Z_{t-7}, Z_{t-4}	MAPE	5.44	4.50	5.60	4.64	4.80
	RMSE	65.98	56.89	67.78	59.62	61.49

Sama halnya dengan kriteria untuk *in-sample*, diketahui bahwa *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$ cenderung memberikan RMSE dan MAPE yang kecil pada data *out-sample*. Fungsi keanggotaan *Generalized Bell*, *Triangular*, dan *Pi* memberikan nilai MAPE paling kecil berturut-turut adalah sebesar 3.94, 3.81, dan 3.81. Secara visual, kriteria kebaikan model dengan menggunakan MAPE dapat ditunjukkan oleh plot individual MAPE berikut ini.

**Gambar 4.12** Plot Individual MAPE *Out-sample* Berdasarkan Fungsi Keanggotaan: (1) Gauss, (2) Gbell, (3) Trap,(4) Tri, (5) Pi

Pemodelan ANFIS dengan jumlah *input* sebanyak tiga yaitu $Z_{t-8}, Z_{t-7}, Z_{t-1}$ dan sejumlah dua fungsi keanggotaan serta jenis fungsi keanggotaan *Pi* dan *Generalized Bell* memberikan hasil peramalan *out-sample* yang lebih baik ditinjau berdasarkan nilai MAPE. Adapun peramalan oleh model ANFIS dengan setiap lima keanggotaan yang dibandingkan dengan data asli adalah sebagai berikut.



Gambar 4.13 Plot Time Series Perbandingan Peramalan ANFIS dan Data Asli

Secara keseluruhan, pemodelan ANFIS yang memberikan nilai MAPE dan RMSE yang terkecil berdasarkan kriteria *out-sample* adalah model ANFIS dengan jenis fungsi keanggotaan *Pi* dengan MAPE sebesar 3.81 % dan RMSE sebesar 51.30. Peramalan model ANFIS terbaik ditunjukkan oleh Tabel 4.51. Interpretasi model ANFIS menunjukkan bahwa jumlah penumpang pada waktu ke-(t) dipengaruhi oleh jumlah penumpang pada waktu ke-($t-1$), ($t-7$), dan ($t-8$). Sehingga ANFIS dengan fungsi keanggotaan *Pi* dibandingkan dengan pemodelan ARIMA terbaik.

4.4 Perbandingan Pemodelan ARIMA dan ANFIS

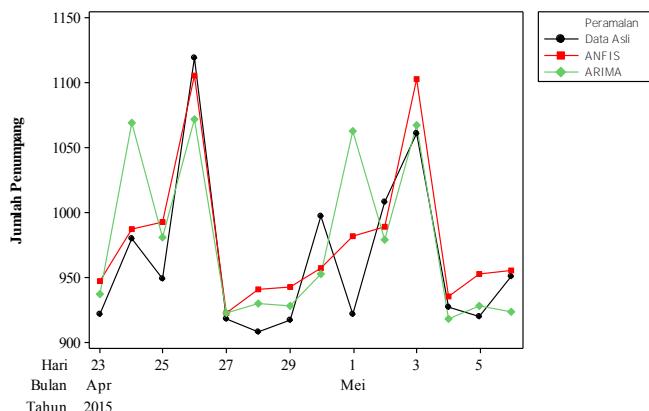
Perbandingan dilakukan terhadap pemodelan ARIMA terbaik yaitu ARIMA ([4,6],1,1) (0,1,1)⁷ dan model ANFIS terbaik

yaitu ANFIS dengan jenis *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$, dua fungsi keanggotaan, dan jenis fungsi keanggotaan bentuk kurva P_i .

Tabel 4.50 Perbandingan Kriteria Kebaikan Model untuk *Out-sample* pada Model ANFIS Terbaik dan ARIMA Terbaik

Model	RMSE	MAPE
ANFIS	51.30	3.81 %
ARIMA	64.63	4.67 %

Secara visual, berikut ini ditunjukkan kedua permalan dari model ARIMA terbaik dan model ANFIS terbaik yaitu ANFIS dengan jenis *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$ dua fungsi keanggotaan, dan jenis fungsi keanggotaan bentuk kurva P_i .



Gambar 4.14 Plot Time Series Perbandingan Peramalan ANFIS, ARIMA, dan Data Asli

Model ARIMA terbaik memiliki MAPE sebesar 4.67 % dan RMSE sebesar 64.63 sedangkan model ANFIS terbaik memiliki MAPE dan RMSE berturut-turut adalah 3.81 % dan 51.30. Berdasarkan kriteria kebaikan model yaitu MAPE dan RMSE yang diterapkan pada data *out-sample*, maka dapat diketahui MAPE dan RMSE model ANFIS lebih kecil daripada model ARIMA, se-

hingga model ANFIS memiliki kemampuan peramalan jumlah penumpang kereta api kertajaya yang lebih baik dibandingkan dengan model ARIMA. Hal tersebut dapat divisualisasikan dengan plot *time series* pada gambar 4.11 yang diketahui bahwa peramalan menggunakan model ANFIS lebih mendekati data asli jumlah penumpang mulai Kamis, 23 April 2015 sampai dengan Rabu, 6 Mei 2015. Namun, kedua model telah mampu meramalkan jumlah penumpang selama 14 periode ke depan dengan MAPE yang dihasilkan adalah kurang dari 5 %. Adapun hasil peramalan mulai tanggal 23 April 2015 sampai dengan 6 Mei 2015 dari kedua model yaitu model ARIMA ([4,6],1,1) (0,1,1)⁷ dan model ANFIS dengan jenis *input* $Z_{t-8}, Z_{t-7}, Z_{t-1}$, dua fungsi keanggotaan, dan jenis fungsi keanggotaan bentuk kurva *pi* ditunjukkan oleh Tabel 4.49.

Tabel 4.51 Peramalan *Out-sample* oleh Model ARIMA dan ANFIS

Periode	Hari	Jumlah Penumpang (Orang)		
		Data Asli	ANFIS	ARIMA
23 April 2015	Kamis	922	947	937
24 April 2015	Jumat	980	987	1069
25 April 2015	Sabtu	949	993	981
26 April 2015	Minggu	1119	1106	1072
27 April 2015	Senin	918	922	923
28 April 2015	Selasa	908	941	930
29 April 2015	Rabu	917	943	928
30 April 2015	Kamis	997	957	953
1 Mei 2015	Jumat	922	982	1063
2 Mei 2015	Sabtu	1008	989	979
3 Mei 2015	Minggu	1061	1102	1067
4 Mei 2015	Senin	927	935	918
5 Mei 2015	Selasa	920	953	928
6 Mei 2015	Rabu	951	956	924

Halaman ini sengaja dikosongkan

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Analisis yang telah dilakukan terhadap jumlah penumpang kereta api Kertajaya memberikan beberapa kesimpulan sebagai berikut ini.

1. Jumlah penumpang cenderung memiliki karakteristik yang sama dan berulang setiap satu minggu atau dapat dikatakan memiliki pola musiman tujuh dan jumlah penumpang pada hari Jumat, Sabtu, dan Minggu cenderung tinggi. Sepanjang tahun 2014 sampai dengan 2015 jumlah penumpang berfluktuatif dan pada Bulan Januari, Februari, April, dan Mei tahun 2015 di mana terjadi penyesuaian tarif kereta api menjadi naik, jumlah penumpang cenderung menurun.
2. Model ARIMA memenuhi asumsi *white noise* namun tidak berdistribusi normal hal tersebut dikarenakan kurva residual model berbentuk leptokurtik. Model ARIMA ([4,6],1,1) (0,1,1)⁷ memiliki MAPE dan RMSE yang lebih kecil yaitu 4.67 % dan 64.26 dari pada model ARIMA yang lainnya. Jadi, model ARIMA ([4,6],1,1)(0,1,1)⁷ menunjukkan bahwa jumlah penumpang kereta api kelas ekonomi Kertajaya pada waktu ke- t dipengaruhi oleh jumlah penumpang pada waktu ke-($t-1$),($t-4$),($t-5$),($t-6$), ($t-7$), ($t-8$), ($t-11$), ($t-12$), ($t-13$), dan ($t-14$). Peramalan yang dihasilkan oleh pemodelan ARIMA ([4,6],1,1)(0,1,1)⁷ ditunjukkan oleh Tabel 4.51
3. Fungsi keanggotaan bentuk kurva P_i dan jenis *input* Z_{t-8} , Z_{t-7} , Z_{t-1} , dan dua fungsi keanggotaan pada model ANFIS memiliki akurasi yang lebih tinggi yang ditunjukkan oleh MAPE dan RMSE lebih kecil sebesar berturut-turut 3.81% dan 51.30 dibandingkan MAPE dan RMSE model ANFIS dengan fungsi keanggotaan dan jenis *input* yang lain. Interpretasi model ANFIS menunjukkan bahwa jumlah penumpang pada waktu ke- t dipengaruhi oleh jumlah penum-

- pang pada waktu ke- $(t-1)$, $(t-7)$, dan $(t-8)$. Peramalan yang dihasilkan oleh pemodelan ANFIS dengan fungsi keanggotaan bentuk kurva P_i dan jenis *input* Z_{t-8} , Z_{t-7} , Z_{t-1} dan dua fungsi keanggotaan ditunjukkan oleh Tabel 4.51.
4. Data jumlah penumpang dapat diramalkan dengan lebih baik bila menggunakan model ANFIS terbaik yaitu ANFIS dengan fungsi keanggotaan bentuk kurva P_i dan jenis *input* Z_{t-8} , Z_{t-7} , Z_{t-1} ditinjau berdasarkan MAPE dan RMSE yang didapatkan lebih kecil daripada model ARIMA terbaik yaitu ARIMA $([4,6],1,1)(0,1,1)^7$. Hal tersebut dapat disebabkan oleh suatu *time series* jumlah penumpang teridentifikasi sebagai data nonlinier sehingga sulit bila dianalisis menggunakan pendekatan linier ARIMA Box-Jenkins.

5.2 Saran

Saran yang dapat diberikan adalah pada penelitian selanjutnya dapat melakukan peramalan menggunakan pendekatan *soft computing* untuk meramalkan jumlah penumpang apabila data jumlah penumpang bersifat nonlinier. Peramalan dapat pula dilakukan untuk satu periode ke depan.

DAFTAR PUSTAKA

- Atsalakis, G., Nezis, D., & Matalliotakis, G. (2008). Forecasting Mortality Rate Using a Neural Network with Fuzzy Inference System. *International Workshop on Applied Probability* (p. 806). Rethymnon: Department of Economics, University of Crete.
- Avci, E. (2008). Comparison of Wavelet Families for Texture Classification by Using Wavelet Packet Entropy Adaptive Network Based Fuzzy Inference System. *Applied Soft Computing*, 8(1), 225-231.
- BPS. (2014, Oktober 1). Berita Resmi Statistik. *Perkembangan Pariwisata dan Transportasi Nasional Agustus 2014*, pp. 1-10.
- Cheng, C.-H., Wei, L.-Y., & Chen, Y.-S. (2009). Fusion ANFIS Models based on Multi-Stock Volatility Causality for TAIEX Forecasting. *Neurocomputing* 72, 3462-3468.
- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis with Applications in R*. New York: Springer.
- Daniel, W. W. (2000). *Applied Nonparametric Statistics, second edition*. Dallas: Cengage Learning.
- Dickey, D., & Fuller, W. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*, 427-431.
- Galavi, H., Mirzaei, M., Shui, L. T., & Valizadeh, N. (2013). Klang River-Level Forecasting Using ARIMA and ANFIS. *American Water Works Association Journal*, E496-E506.
- Gyu-jin, J., Jin-pyung, K., Jee-hyong, L., & Moon-hyun, K. (2011). ANFIS based Short-term Prediction of Passenger Volume in Urban Rail Transit. *International Symposium on Advanced Intelligent systems (ISIS)*. USA: Springer.

- Jang , R. J.-S., Sun, C., & Mizutani, E. (1997). *Neuro-Fuzzy and Soft Computing*. London: Prentice Hall.
- Jang, J.-S. R. (1993). ANFIS: Adaptive-Network-Based Inference System. *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 23, 665-885.
- KAI. (2014, Maret 06). *PT. Kereta Api Indonesia*. Retrieved from Pemerintah Subsidi Penumpang KA Kelas Ekonomi : <https://www.kereta-api.co.id>
- Kostenko, A.V.,& Hyndman, R.J. (2008). Forecasting Without SignificanceTest?.<http://robjhyndman.com/papers/sst2.pdf>.
- Makridakis, S., & Hibon, M. (1995). *Evaluating Accuracy (or Error) Measures*. INSEAD working paper. Fontainebleau: INSEAD.
- Nurvitasisari, Y & Irhamah. (2012). Pendekatan Fungsi Transfer sebagai Input Adaptive Neuro-Fuzzy Inference System (ANFIS) dalam peramalan Kecepatan ANgin Rata-rata Harian di Sumenep. *Jurnal Sains dan Seni ITS*, 62-68.
- Padang, E., Tarigan, G., & Sinulingga, U. (2013). Peramalan Jumlah Penumpang Kereta Api Medan-Rantau Prapat dengan Metode Pemulusan Eksponensial Holt-Winters. *Jurnal Saintika Matematika*, 161-174.
- Stephen, M. A. (1993). *Aspects of Goodness of Fit*. California: Technical Report, Department of Statistics, Stanford University.
- Sugeno, M., & Kang, G. T. (1988). Structure Identification of Fuzzy Model . *Fuzzy Sets and Systems*, 28:15-33.
- Takagi, T., & Sugeno, M. (1983). Derivation of Fuzzy Control Rules from Human Operator's Control Actions. *The IFAC Symposium on Fuzzy Information, Knowledge Representation and Decision Analysis*, (pp. 55-60).
- Takagi, T., & Sugeno, M. (1985). Fuzzy Identification of Systems and Its Applications to Modelling and Control. *IEEE*

- Transactions on Systems, Man, and Cybernetics*, (pp. 15:116-132).
- Varedi, M. (2011). *Forecasting Seat Sales in Passenger Airlines Using the Reverse Traffic*. German: VDM Verlag.
- Wei, W. (2006). *Time Series Univariate and Multivariate Methods*. Canada: Addison Wesley.
- Widhianti, N., & Wutaqa, D. U. (2013). Peramalan Banyak Penumpang Kereta DAOP VI Yogyakarta Menggunakan Model Time Series dengan Variasi Kalender Islam Regarima. *Seminar Nasional Matematika dan Pendidikan Matematika* (pp. 181-190). Yogyakarta: FMIPA UNY.
- Widiyanto, T. A. (2013). Peramalan Jumlah Penumpang Kereta Api Logawa dan Sritanjung di DAOP IX Jember. *Jurnal Sains dan Seni ITS*, 2337-3520.
- Yayar, R., Hekim, M., Yilmaz, V., & Bakirci, F. (2011). A Comparison of ANFIS and ARIMA Techniquesin the Forecasting of Electric Energy Consumption of Tokat Province in Turkey. *Journal of Economic and Social Studies*, 87-112.
- Yilmaz, I., & Kaynar, O. (2011). Multiple Regression, ANN (RBF, MLP) and ANFIS Models for Prediction. *Expert Systems with Applications* 38, 5958–5966.
- Zadeh, L. A. (1965). Fuzzy Sets. *Information and Control*, 8:338-353.
- Zadeh, L. A. (1992). Fuzzy Logic. Neural Networks and Soft Computing. *One-page Course Announcement of CS 294-4, Spring 1993*. Berkeley: The University of California.

Halaman ini sengaja dikosongkan

LAMPIRAN

Lampiran 1 : Data Jumlah Penumpang Kereta Api Ekonomi Kertajaya

Tanggal	Hari	t	Jumlah Penumpang
1-Mei-14	Kamis	1	1019
2-Mei-14	Jumat	2	1004
3-Mei-14	Sabtu	3	977
4-Mei-14	Minggu	4	1160
5-Mei-14	Senin	5	951
6-Mei-14	Selasa	6	948
7-Mei-14	Rabu	7	958
8-Mei-14	Kamis	8	954
9-Mei-14	Jumat	9	1007
10-Mei-14	Sabtu	10	982
11-Mei-14	Minggu	11	1116
12-Mei-14	Senin	12	981
13-Mei-14	Selasa	13	960
14-Mei-14	Rabu	14	1019
15-Mei-14	Kamis	15	980
16-Mei-14	Jumat	16	1049
17-Mei-14	Sabtu	17	980
18-Mei-14	Minggu	18	1102
19-Mei-14	Senin	19	963
:	:	:	:
:	:	:	:
6-May-15	Rabu	371	951

Lampiran 2 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([1,2,3,6],1,1) (0,1,1)⁷

```
data model1;
input y;
datalines;
1019
1004
977
:
:
923
922
;

/*tahap identifikasi*/
proc arima data=model1;
identify var=y(1,7);
run;
/*tahap estimasi*/
estimate p=(1,2,3,6) q=(4)(7) noconstant method=cls;
run;
/*tahap peramalan*/
forecast out=hasil lead=14;

/*tahap deteksi outlier*/
outlier maxnum=30 alpha=0.00135;

/*menampilkan output*/
proc print data=hasil;
run;

/*tahap uji normalitas residual*/
proc univariate data=hasil normal;
var residual;
run;
```

Lampiran 3 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1)⁷

```
data model1;
input y;
datalines;
1019
1004
977
:
:
923
922
;

/*tahap identifikasi*/
proc arima data=model1;
identify var=y(1,7);
run;

/*tahap estimasi*/
estimate p=(4,6) q=(1) (7) noconstant method=cls;
run;

/*tahap peramalan*/
forecast out=hasil lead=14;

/*tahap deteksi outlier*/
outlier maxnum=30 alpha=0.00135;

/*menampilkan output*/
proc print data=hasil;
run;

/*tahap uji normalitas residual*/
proc univariate data=hasil normal;
var residual;
run;
```

Lampiran 4 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA (0,1, [1,4]) (0,1,1)⁷

```
data model1;
input y;
datalines;
1019
1004
977
:
:
923
922
;

/*tahap identifikasi*/
proc arima data=model1;
identify var=y(1,7);
run;

/*tahap estimasi*/
estimate q=(1,4) (7) noconstant method=cls;
run;

/*tahap peramalan*/
forecast out=hasil lead=14;

/*tahap deteksi outlier*/
outlier maxnum=30 alpha=0.00135;

/*menampilkan output*/
proc print data=hasil;
run;

/*tahap uji normalitas residual*/
proc univariate data=hasil normal;
var residual;
run;
```

Lampiran 5 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA (1,0,1) (0,1,1)⁷

```
data model1;
input y;
datalines;
1019
1004
977
:
:
923
922
;

/*tahap identifikasi*/
proc arima data=model1;
identify var=y(7);
run;

/*tahap estimasi*/
estimate p=(1) q=(1) (7) noconstant method=cls;
run;

/*tahap peramalan*/
forecast out=hasil lead=14;

/*tahap deteksi outlier*/
outlier maxnum=30 alpha=0.00135;

/*menampilkan output*/
proc print data=hasil;
run;

/*tahap uji normalitas residual*/
proc univariate data=hasil normal;
var residual;
run;
```

Lampiran 6 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA (1,0,[2]) (0,1,1)⁷

```
data model1;
input y;
datalines;
1019
1004
977
:
:
923
922
;

/*tahap identifikasi*/
proc arima data=model1;
identify var=y(7);
run;

/*tahap estimasi*/
estimate p=(1) q=(2) (7) noconstant method=cls;
run;

/*tahap peramalan*/
forecast out=hasil lead=14;

/*tahap deteksi outlier*/
outlier maxnum=30 alpha=0.00135;

/*menampilkan output*/
proc print data=hasil;
run;

/*tahap uji normalitas residual*/
proc univariate data=hasil normal;
var residual;
run;
```

Lampiran 7 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA (2,0,[14]) (1,1,0)⁷

```
data model1;
input y;
datalines;
1019
1004
977
:
:
923
922
;

/*tahap identifikasi*/
proc arima data=model1;
identify var=y(7);
run;

/*tahap estimasi*/
estimate p=(1,2) (7) q=(14) noconstant method=cls;
run;

/*tahap peramalan*/
forecast out=hasil lead=14;

/*tahap deteksi outlier*/
outlier maxnum=30 alpha=0.00135;

/*menampilkan output*/
proc print data=hasil;
run;

/*tahap uji normalitas residual*/
proc univariate data=hasil normal;
var residual;
run;
```

Lampiran 8 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([1,2,3,6],1,1) (0,1,1)⁷ dengan Deteksi *Outlier*

```
data model1;
input x;
datalines;
1019
1004
977
:
923
922
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
.
;
data model1;
set model1;
if _n_=142 then AO142=1.0;else AO142=0.0;
if _n_=172 then AO172=1.0;else AO172=0.0;
if _n_=338 then AO338=1.0;else AO338=0.0;
if _n_=351 then AO351=1.0;else AO351=0.0;
proc arima data=model1;
identify var=x(1,7) crosscorr=(AO142(1,7) AO172(1,7) AO338(1,7) AO351(1,7));
estimate
p=(1,2,3)
q=(4,6)(7)
input=(AO142 AO172 AO338 AO351)
noconstant method=cls;
forecast out=ramalan lead=14;
outlier maxnum=30 alpha=0.00135;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 9 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1)⁷ dengan Deteksi *Outlier*

```
data model1;
input x;
datalines;
1019
1004
977
:
:
923
922
:
:
:
:
:
:
;
data model1;
set model1;
if _n_=142 then AO142=1.0;else AO142=0.0;
if _n_=338 then AO338=1.0;else AO338=0.0;
if _n_=172 then AO172=1.0;else AO172=0.0;
if _n_=351 then AO351=1.0;else AO351=0.0;
if _n_=88 then AO88=1.0;else AO88=0.0;
if _n_>=91 then LS91=1.0;else LS91=0.0;
```

Lampiran 9 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1)⁷ dengan Deteksi *Outlier* (lanjutan)

```
proc arima data=model1;
identify var=x(1,7) crosscorr=(AO142(1,7) AO338(1,7) AO172(1,7) AO351(1,7)
AO88(1,7) LS91(1,7));
estimate
p=(1,6)
q=(1)(7)
input=(AO142 AO338 AO172 AO351 AO88 LS91)
noconstant method=cls;
forecast out=ramalan lead=14;
outlier maxnum=30 alpha=0.00135;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 10 : Program SAS untuk Peramalan Jumlah Penumpang menggunakan ARIMA (0,1, [1,4]) (0,1,1)⁷ dengan Deteksi *Outlier*

```
data model1;
input x;
datalines;
1019
1004
977
:
:
923
922
:
:
:
:
:
:
;
data model1;
set model1;
if _n_=142 then AO142=1.0;else AO142=0.0;
if _n_=338 then AO338=1.0;else AO338=0.0;

proc arima data=model1;
identify var=x(1,7) crosscorr=(AO142(1,7) AO338(1,7));
estimate
q=(1,4)(7)
input=(AO142 AO338)
noconstant method=cls;
forecast out=ramalan lead=14;
outlier maxnum=30 alpha=0.00135;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 11 : Hasil Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1)⁷

The ARIMA Procedure Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	Approx t Value	Pr > t	Lag				
MA1,1	0.46942	0.06674	7.03	<.0001	4				
MA2,1	0.74566	0.04009	18.60	<.0001	7				
AR1,1	-0.66547	0.05097	-13.06	<.0001	1				
AR1,2	-0.51390	0.06385	-8.05	<.0001	2				
AR1,3	-0.45138	0.06739	-6.70	<.0001	3				
AR1,4	-0.09862	0.04793	-2.06	0.0404	6				
Variance Estimate 2557.205									
Std Error Estimate 50.56881									
AIC 3734.855									
SBC 3757.985									
Number of Residuals 349									
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	Pr > DF	ChiSq	Autocorrelations-----					
6	.	0	.	0.000	0.008	0.008	0.012	0.016	-0.033
12	3.00	6	0.8087	-0.016	-0.000	-0.032	0.026	0.009	-0.068
18	7.68	12	0.8094	0.051	-0.030	0.045	0.002	0.032	0.078
24	9.53	18	0.9462	-0.004	0.047	0.021	-0.020	-0.038	-0.019
30	12.71	24	0.9707	-0.023	0.048	0.026	0.013	-0.040	-0.055
36	17.34	30	0.9683	0.042	0.077	-0.021	0.012	0.057	0.019
42	19.16	36	0.9904	0.003	-0.031	-0.015	0.023	0.010	0.052
48	21.46	42	0.9964	-0.021	-0.038	0.048	0.027	0.017	-0.024
Period(s) of Differencing 1,7									
No mean term in this model.									
Forecasts for variable y									
Obs	Forecast	Std Error	95% Confidence Limits						
358	937.9931	50.5688	838.8800	1037.1061					
359	1077.8886	53.3234	973.3765	1182.4006					
360	968.9336	54.9629	861.2083	1076.6589					
361	1078.8954	55.8982	969.3369	1188.4540					

Lampiran 11 : Hasil Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1)⁷ (Lanjutan)

362	909.7672	56.1752	799.6659	1019.8685
363	933.7889	57.4169	821.2540	1046.3239
364	921.4016	57.7815	808.1519	1034.6512
365	953.3540	62.9950	829.8861	1076.8220
366	1063.0489	64.3201	936.9839	1189.1139
367	975.1089	65.8741	845.9980	1104.2197
368	1068.9651	66.9009	937.8418	1200.0884
369	912.5959	67.8891	779.5357	1045.6560
370	928.0409	69.1066	792.5945	1063.4873
371	920.5000	70.0380	783.2280	1057.7720

Outlier Detection Summary

Maximum number searched	30
Number found	25
Significance used	0.00135

Tests for Normality

Test	--Statistic---	-----p Value-----
------	----------------	-------------------

Shapiro-Wilk	W	0.944961	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.089227	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.940858	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	5.269624	Pr > A-Sq	<0.0050

Lampiran 12 : Hasil Peramalan Jumlah Penumpang menggunakan ARIMA (0,1, [1,4]) (0,1,1)⁷

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Standard		Approx				
	Estimate	Error	t Value	Pr > t	Lag		
MA1,1	0.72854	0.03872	18.81	<.0001	1		
MA1,2	0.08108	0.03898	2.08	0.0382	4		
MA2,1	0.73068	0.03859	18.94	<.0001	7		
Variance Estimate 2604.054							
Std Error Estimate 51.02994							
AIC 3738.23							
SBC 3749.795							
Number of Residuals 349							
* AIC and SBC do not include log determinant.							
Autocorrelation Check of Residuals							
To Lag	Chi-Square	Pr > DF	ChiSq	Autocorrelations			

6	7.54	3	0.0566	0.048	-0.014	-0.078	-0.043
12	9.41	9	0.4000	0.015	-0.012	-0.002	0.019
18	14.50	15	0.4877	0.050	-0.048	0.049	0.006
24	16.96	21	0.7133	-0.001	0.054	0.013	-0.025
30	21.47	27	0.7639	-0.013	0.058	0.043	0.002
36	25.60	33	0.8175	0.040	0.076	-0.009	0.010
42	27.96	39	0.9058	0.001	-0.045	-0.024	0.029
48	31.34	45	0.9389	-0.026	-0.040	0.045	0.034
Period(s) of Differencing 1,7							
No mean term in this model.							
Forecasts for variable y							
Obs	Forecast	Std Error	95% Confidence Limits				
358	957.2521	51.0299	857.2352	1057.2689			
359	1064.0980	52.8767	960.4616	1167.7343			
360	980.6243	54.6611	873.4906	1087.7580			

Lampiran 12 : Hasil Peramalan Jumlah Penumpang menggunakan ARIMA (0,1, [1,4]) (0,1,1)⁷ (Lanjutan)

361	1068.0755	56.3890	957.5551	1178.5959
362	917.2754	57.2198	805.1268	1029.4241
363	928.7364	58.0386	814.9828	1042.4900
364	923.6785	58.8461	808.3423	1039.0147
365	957.7377	63.3496	833.5749	1081.9006
366	1062.2605	64.7607	935.3318	1189.1893
367	978.5187	66.1418	848.8831	1108.1543
368	1065.8106	67.4947	933.5234	1198.0977
369	915.0105	68.6119	780.5336	1049.4874
370	926.4715	69.7113	789.8399	1063.1031
371	921.4136	70.7935	782.6608	1060.1664

Outlier Detection Summary

Maximum number searched 30
Number found 24
Significance used 0.00135

Tests for Normality

Test --Statistic--- -----p Value-----

Shapiro-Wilk W 0.943814 Pr < W <0.0001
Kolmogorov-Smirnov D 0.093923 Pr > D <0.0100
Cramer-von Mises W-Sq 0.877886 Pr > W-Sq <0.0050
Anderson-Darling A-Sq 4.933005 Pr > A-Sq <0.0050

Lampiran 13 : Hasil Peramalan Jumlah Penumpang menggunakan ARIMA $([1,2,3,6],1,1)$ $(0,1,1)^7$ dengan Deteksi Outlier

Forecasts for variable x

Obs	Forecast	Std Error	95% Confidence Limits	
358	966.7586	47.6759	873.3155	1060.2017
359	1100.9716	51.0854	1000.8460	1201.0972
360	975.6932	52.8404	872.1279	1079.2584
361	1075.2292	53.8582	969.6690	1180.7894
362	909.0950	54.2746	802.7187	1015.4713
363	931.3814	55.6999	822.2116	1040.5511
364	921.6952	55.9586	812.0183	1031.3721
365	982.4385	60.7879	863.2965	1101.5805
366	1092.5992	62.2517	970.5882	1214.6102
367	977.8640	63.8003	852.8176	1102.9104
368	1067.8590	64.7127	941.0244	1194.6936
369	912.1853	65.5401	783.7290	1040.6416
370	926.4084	66.6175	795.8406	1056.9762
371	920.6915	67.4243	788.5423	1052.8408

Outlier Detection Summary

Maximum number searched	30
Number found	24
Significance used	0.00135

Tests for Normality

Test	--Statistic---	-----p Value-----
------	----------------	-------------------

Shapiro-Wilk	W	0.961771	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.075574	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.685676	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	3.852239	Pr > A-Sq	<0.0050

Lampiran 14 : Hasil Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1)⁷ dengan Deteksi *Outlier*

Lampiran 14 : Hasil Peramalan Jumlah Penumpang menggunakan ARIMA ([4,6],1,1) (0,1,1)⁷ dengan Deteksi *Outlier* (Lanjutan)

Forecasts for variable x				
Obs	Forecast	Std Error	95% Confidence Limits	
358	965.6737	46.6656	874.2108	1057.1367
359	1096.7683	50.4419	997.9041	1195.6325
360	978.0694	52.1110	875.9338	1080.2050
361	1071.1462	53.4184	966.4481	1175.8443
362	918.9235	54.6320	811.8468	1026.0002
363	930.5618	55.8059	821.1842	1039.9394
364	928.5111	55.9680	818.8158	1038.2063
365	982.8495	60.0648	865.1248	1100.5743
366	1096.8844	61.7918	975.7746	1217.9941
367	978.6823	63.1657	854.8797	1102.4849
368	1067.6332	64.4572	941.2995	1193.9669
369	915.1660	65.7138	786.3694	1043.9626
370	926.9106	67.1607	795.2780	1058.5432
371	923.2571	68.1261	789.7325	1056.7818

Outlier Detection Summary			
Maximum number searched	30		
Number found	20		
Significance used	0.00135		

Tests for Normality			
Test	--Statistic---	-----p Value-----	
Shapiro-Wilk	W 0.96558	Pr < W <0.0001	
Kolmogorov-Smirnov	D 0.077685	Pr > D <0.0100	
Cramer-von Mises	W-Sq 0.642649	Pr > W-Sq <0.0050	
Anderson-Darling	A-Sq 3.555145	Pr > A-Sq <0.0050	

Lampiran 15 : Hasil Peramalan Jumlah Penumpang menggunakan ARIMA (0,1, [1,4]) (0,1,1)⁷ dengan Deteksi *Outlier*

Conditional Least Squares Estimation									
Parameter	Standard		Approx			Lag	Variable	Shift	
	Estimate	Error	t Value	Pr > t					
MA1,1	0.71895	0.03982	18.06	<.0001	1	x		0	
MA1,2	0.08855	0.03954	2.24	0.0258	4	x		0	
MA2,1	0.70645	0.04029	17.54	<.0001	7	x		0	
NUM1	220.16601	41.92118	5.25	<.0001	0	AO142		0	
NUM2	-141.28699	42.78555	-3.30	0.0011	0	AO338		0	
Variance Estimate 2355.139									
Std Error Estimate 48.52977									
AIC 3705.143									
SBC 3724.418									
Number of Residuals 349									
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.92	3	0.0745	0.046	-0.011	-0.070	-0.023	0.082	-0.071
12	8.12	9	0.5217	-0.013	-0.018	-0.011	0.016	0.000	-0.049
18	13.79	15	0.5418	0.074	-0.007	0.041	-0.055	0.019	0.070
24	15.27	21	0.8090	0.009	0.048	0.008	-0.023	-0.031	-0.008
30	20.01	27	0.8303	-0.035	0.055	0.048	0.013	-0.068	-0.032
36	23.48	33	0.8895	0.034	0.082	0.011	0.009	0.025	0.015
42	27.40	39	0.9184	-0.002	-0.066	-0.020	0.014	0.033	0.062
48	30.55	45	0.9508	-0.026	-0.028	0.049	0.042	0.033	-0.033
Period(s) of Differencing 1,7									
No mean term in this model.									
Forecasts for variable x									
Obs	Forecast	Std Error	95% Confidence Limits						
358	955.6755	48.5298	860.5589	1050.7921					
359	1087.1961	50.4100	988.3942	1185.9980					
360	978.7774	52.2227	876.4229	1081.1320					
361	1066.1867	53.9745	960.3987	1171.9747					
362	914.3745	54.7769	807.0137	1021.7354					
363	926.3424	55.5678	817.4314	1035.2533					
364	921.2813	56.3476	810.8419	1031.7206					

Lampiran 15 : Hasil Peramalan Jumlah Penumpang menggunakan ARIMA (0,1, [1,4]) (0,1,1)⁷ dengan Deteksi *Outlier* (Lanjutan)

365	955.1551	61.0855	835.4297	1074.8805
366	1084.4866	62.5264	961.9371	1207.0360
367	975.9177	63.9348	850.6078	1101.2275
368	1063.2717	65.3128	935.2610	1191.2825
369	911.4596	66.4213	781.2762	1041.6430
370	923.4274	67.5116	791.1070	1055.7478
371	918.3663	68.5846	783.9430	1052.7897

Outlier Detection Summary

Maximum number searched	30
Number found	24
Significance used	0.00135

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.953966	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.083683	Pr > D <0.0100
Cramer-von Mises	W-Sq 0.773382	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 4.306106	Pr > A-Sq <0.0050

Lampiran 16: Program R dan Hasil untuk Uji *Terasvirta* dan *White*

```
>Data=read.table("D://kertajaya.txt")
>x1=as.ts(Data)
>terasvirta.test(x1,type="F")

Teraesvirta Neural Network Test

data: x1
F = 5.0584, df1 = 2, df2 = 368, p-value = 0.006805

> white.test(x1)

White Neural Network Test

data: x1
X-squared = 12.1487, df = 2, p-value = 0.002301
```

Lampiran 17. Program Pemodelan ANFIS dengan *Gbellmf* Menggunakan Matlab

```
% memanggil data
x=load('d:/kertajaya.txt');

% input untuk data insample
xti_8=x(1:349);
xti_7=x(2:350);
xti_1=x(8:356);
% matriks
xti=[xti_8 xti_7 xti_1];

% input untuk data outsample
xto_8=x(350:363);
xto_7=x(351:364);
xto_1=x(357:370);
xto=[xto_8 xto_7 xto_1];

% target
y_i=x(9:357);
y_o=x(358:371);

% ANFIS
mfType='gbellmf';
numMFs=2;
epoch_n=500
in_fis1=genfis1([xti y_i],numMFs,mfType);
out_fis1=anfis([xti y_i],in_fis1,epoch_n);

% Peramalan k-tahap ke depan
y_ihat=evalfis(xti,out_fis1);
yt=x;
for i=358:371;
    yt(i)=evalfis([yt(i-8) yt(i-7) yt(i-1)],out_fis1);
end
y_ohat=yt(358:371)

%residual
er_in=y_i-y_ihat;
er_out=y_o-y_ohat;
rmse_in=sqrt(sum(er_in.*er_in)/length(er_in))
rmse_out=sqrt(sum(er_out.*er_out)/length(er_out))
mape_in=sum(abs(er_in./y_i)/length(er_in))*100
mape_out=sum(abs(er_out./y_o)/length(er_out))*100
showfis(in_fis1)
showfis(out_fis1)
```

Lampiran 18. Hasil dari Pemodelan ANFIS dengan *Gbellmf*
Menggunakan Matlab

ANFIS info:

Number of nodes: 34
Number of linear parameters: 32
Number of nonlinear parameters: 18
Total number of parameters: 50
Number of training data pairs: 349
Number of checking data pairs: 0
Number of fuzzy rules: 8

Start training ANFIS ...

1 46.088
2 46.0864
3 46.0848
4 46.0831
5 46.0815

Step size increases to 0.011000 after epoch 5.

:
:
496 45.5927
497 45.5927
498 45.5926
499 45.5926
500 45.5924

Step size decreases to 0.004755 after epoch 500.

Designated epoch number reached --> ANFIS training completed at epoch 500.

y_ohat =
1.0e+003 *
0.9454
0.9271
1.0128
1.0750
0.9258
0.9391
0.9408
0.9555
0.9458
1.0022
1.0736
0.9431
0.9518
0.9536

Lampiran 18. Hasil dari Pemodelan ANFIS dengan *Gbellmf*
Menggunakan Matlab (Lanjutan)

```
rmse_in =  
45.5924  
  
rmse_out =  
52.1795  
  
mape_in =  
3.3154  
  
mape_out =  
3.9411  
  
1. Name      anfis  
2. Type      sugeno  
3. Inputs/Outputs [3 1]  
4. NumInputMFs [2 2 2]  
5. NumOutputMFs 8  
6. NumRules    8  
7. AndMethod   prod  
8. OrMethod    max  
9. ImpMethod   prod  
10. AggMethod  max  
11. DefuzzMethod wtaver  
12. InLabels   input1  
13.           input2  
14.           input3  
15. OutLabels  output  
16. InRange    [884 1242]  
17.           [884 1242]  
18.           [884 1242]  
19. OutRange   [884 1242]  
20. InMFLabels in1mf1  
21.           in1mf2  
22.           in2mf1  
23.           in2mf2  
24.           in3mf1  
25.           in3mf2  
26. OutMFLabels out1mf1  
27.           out1mf2  
28.           out1mf3  
29.           out1mf4  
30.           out1mf5  
31.           out1mf6  
32.           out1mf7  
33.           out1mf8
```

Lampiran 18. Hasil dari Pemodelan ANFIS dengan *Gbellmf*
Menggunakan Matlab (Lanjutan)

```

34. InMFTypes    gbellmf
35.          gbellmf
36.          gbellmf
37.          gbellmf
38.          gbellmf
39.          gbellmf
40. OutMFTypes   linear
41.          linear
42.          linear
43.          linear
44.          linear
45.          linear
46.          linear
47.          linear
48. InMFParams   [179 2 884 0]
49.          [179 2 1242 0]
50.          [179 2 884 0]
51.          [179 2 1242 0]
52.          [179 2 884 0]
53.          [179 2 1242 0]
54. OutMFParams  [0 0 0 0]
55.          [0 0 0 0]
56.          [0 0 0 0]
57.          [0 0 0 0]
58.          [0 0 0 0]
59.          [0 0 0 0]
60.          [0 0 0 0]
61.          [0 0 0 0]
62. Rule Antecedent [1 1 1]
63.          [1 1 2]
64.          [1 2 1]
65.          [1 2 2]
66.          [2 1 1]
67.          [2 1 2]
68.          [2 2 1]
69.          [2 2 2]
62. Rule Consequent 1
63.          2
64.          3
65.          4
66.          5
67.          6
68.          7
69.          8

```

Lampiran 18. Hasil dari Pemodelan ANFIS dengan *Gbellmf*
Menggunakan Matlab (Lanjutan)

```
62. Rule Weight    1
63.          1
64.          1
65.          1
66.          1
67.          1
68.          1
69.          1
62. Rule Connection 1
63.          1
64.          1
65.          1
66.          1
67.          1
68.          1
69.          1
1. Name      anfis
2. Type      sugeno
3. Inputs/Outputs [3 1]
4. NumInputMFs [2 2 2]
5. NumOutputMFs 8
6. NumRules     8
7. AndMethod    prod
8. OrMethod     max
9. ImpMethod    prod
10. AggMethod   max
11. DefuzzMethod wtaver
12. InLabels    input1
13.          input2
14.          input3
15. OutLabels   output
16. InRange     [884 1242]
17.          [884 1242]
18.          [884 1242]
19. OutRange    [884 1242]
20. InMFLabels  in1mf1
21.          in1mf2
22.          in2mf1
23.          in2mf2
24.          in3mf1
25.          in3mf2
26. OutMFLabels out1mf1
27.          out1mf2
28.          out1mf3
29.          out1mf4
```

Lampiran 18. Hasil dari Pemodelan ANFIS dengan *Gbellmf*
Menggunakan Matlab (Lanjutan)

```

30.      out1mf5
31.      out1mf6
32.      out1mf7
33.      out1mf8
34. InMFTypes    gbellmf
35.          gbellmf
36.          gbellmf
37.          gbellmf
38.          gbellmf
39.          gbellmf
40. OutMFTypes   linear
41.          linear
42.          linear
43.          linear
44.          linear
45.          linear
46.          linear
47.          linear
48. InMFParams   [178.7 0.5456 883.7 0]
49.          [181.4 1.937 1240 0]
50.          [178.9 -0.5485 883.4 0]
51.          [182 6.202 1239 0]
52.          [176.2 3.952 881.3 0]
53.          [179.7 1.296 1241 0]
54. OutMFParams  [0.547 0.4797 -0.2154 81.19]
55.          [-3.355 2.347 -1.899 4169]
56.          [-0.7927 -4.108 3.043 3560]
57.          [23.34 9.551 -0.9893 -3.077e+004]
58.          [0.5761 -1.635 0.1709 1824]
59.          [-0.7834 1.478 2.264 -1890]
60.          [2.833 4.129 1.939 -8601]
61.          [2.394 -10.49 -5.419 1.315e+004]
62. Rule Antecedent [1 1 1]
63.          [1 1 2]
64.          [1 2 1]
65.          [1 2 2]
66.          [2 1 1]
67.          [2 1 2]
68.          [2 2 1]
69.          [2 2 2]
62. Rule Consequent 1
63.          2
64.          3
65.          4
66.          5

```

Lampiran 18. Hasil dari Pemodelan ANFIS dengan *Gbellmf*
Menggunakan Matlab (Lanjutan)

67.	6
68.	7
69.	8
62. Rule Weight	1
63.	1
64.	1
65.	1
66.	1
67.	1
68.	1
69.	1
62. Rule Connection	1
63.	1
64.	1
65.	1
66.	1
67.	1
68.	1
69.	1

Lampiran 19. Program Pemodelan ANFIS dengan *Gaussmf* Menggunakan Matlab

```
% memanggil data
x=load('d:/kertajaya.txt');

% input untuk data insample
xti_8=x(1:349);
xti_7=x(2:350);
xti_1=x(8:356);
% matriks
xti=[xti_8 xti_7 xti_1];

% input untuk data outsample
xto_8=x(350:363);
xto_7=x(351:364);
xto_1=x(357:370);
xto=[xto_8 xto_7 xto_1];

% target
y_i=x(9:357);
y_o=x(358:371);

% ANFIS
mfType='gaussmf';
numMFs=2;
epoch_n=500
in_fis1=genfis1([xti y_i],numMFs,mfType);
out_fis1=anfis([xti y_i],in_fis1,epoch_n);

% Peramalan k-tahap ke depan
y_ihat=evalfis(xti,out_fis1)
yt=x;
for i=358:371;
    yt(i)=evalfis([yt(i-8) yt(i-7) yt(i-1)],out_fis1);
end
y_ohat=yt(358:371)

% residual
er_in=y_i-y_ihat;
er_out=y_o-y_ohat;
rmse_in=sqrt(sum(er_in.*er_in)/length(er_in))
rmse_out=sqrt(sum(er_out.*er_out)/length(er_out))
mape_in=sum(abs(er_in./y_i)/length(er_in))*100
mape_out=sum(abs(er_out./y_o)/length(er_out))*100
showfis(in_fis1)
showfis(out_fis1)
```

Lampiran 20. Hasil dari Pemodelan ANFIS dengan *Gaussmf* Menggunakan Matlab

ANFIS info:

```
Number of nodes: 34
Number of linear parameters: 32
Number of nonlinear parameters: 12
Total number of parameters: 44
Number of training data pairs: 349
Number of checking data pairs: 0
Number of fuzzy rules: 8
```

Start training ANFIS ...

```
1      46.0948
2      46.0948
3      46.0947
4      46.0947
5      46.0947
```

Step size increases to 0.011000 after epoch 5.

```
:
:
496    45.0581
497    45.0579
498    45.0576
499    45.0571
```

Step size increases to 0.104008 after epoch 499.

```
500    45.0572
```

Designated epoch number reached --> ANFIS training completed at epoch 500.

```
y_ohat =
1.0e+003 *
0.9455
0.9519
1.0624
1.0611
0.9230
0.9368
0.9366
0.9523
0.9554
1.0246
1.0490
0.9458
0.9473
0.9467
```

Lampiran 20. Hasil dari Pemodelan ANFIS dengan *Gaussmf* Menggunakan Matlab (Lanjutan)

```
rmse_in =  
45.0571  
  
rmse_out =  
57.0391  
  
mape_in =  
3.2793  
  
mape_out =  
4.2655  
  
1. Name      anfis  
2. Type      sugeno  
3. Inputs/Outputs [3 1]  
4. NumInputMFs [2 2 2]  
5. NumOutputMFs 8  
6. NumRules   8  
7. AndMethod  prod  
8. OrMethod   max  
9. ImpMethod  prod  
10. AggMethod max  
11. DefuzzMethod wtaver  
12. InLabels   input1  
13.          input2  
14.          input3  
15. OutLabels  output  
16. InRange    [884 1242]  
17.          [884 1242]  
18.          [884 1242]  
19. OutRange   [884 1242]  
20. InMFLabels in1mf1  
21.          in1mf2  
22.          in2mf1  
23.          in2mf2  
24.          in3mf1  
25.          in3mf2  
26. OutMFLabels out1mf1  
27.          out1mf2  
28.          out1mf3  
29.          out1mf4  
30.          out1mf5  
31.          out1mf6  
32.          out1mf7  
33.          out1mf8
```

Lampiran 20. Hasil dari Pemodelan ANFIS dengan *Gaussmf*
Menggunakan Matlab (Lanjutan)

```
34. InMFTypes    gaussmf
35.          gaussmf
36.          gaussmf
37.          gaussmf
38.          gaussmf
39.          gaussmf
40. OutMFTypes   linear
41.          linear
42.          linear
43.          linear
44.          linear
45.          linear
46.          linear
47.          linear
48. InMFParams   [152 884 0 0]
49.          [152 1242 0 0]
50.          [152 884 0 0]
51.          [152 1242 0 0]
52.          [152 884 0 0]
53.          [152 1242 0 0]
54. OutMFParams  [0 0 0 0]
55.          [0 0 0 0]
56.          [0 0 0 0]
57.          [0 0 0 0]
58.          [0 0 0 0]
59.          [0 0 0 0]
60.          [0 0 0 0]
61.          [0 0 0 0]
62. Rule Antecedent [1 1 1]
63.          [1 1 2]
64.          [1 2 1]
65.          [1 2 2]
66.          [2 1 1]
67.          [2 1 2]
68.          [2 2 1]
69.          [2 2 2]
62. Rule Consequent 1
63.          2
64.          3
65.          4
66.          5
67.          6
68.          7
69.          8
```

Lampiran 20. Hasil dari Pemodelan ANFIS dengan *Gaussmf*
Menggunakan Matlab (Lanjutan)

```

62. Rule Weight    1
63.      1
64.      1
65.      1
66.      1
67.      1
68.      1
69.      1
62. Rule Connection 1
63.      1
64.      1
65.      1
66.      1
67.      1
68.      1
69.      1
1. Name      anfis
2. Type      sugeno
3. Inputs/Outputs [3 1]
4. NumInputMFs [2 2 2]
5. NumOutputMFs 8
6. NumRules   8
7. AndMethod  prod
8. OrMethod   max
9. ImpMethod  prod
10. AggMethod max
11. DefuzzMethod wtaver
12. InLabels   input1
13.          input2
14.          input3
15. OutLabels  output
16. InRange    [884 1242]
17.          [884 1242]
18.          [884 1242]
19. OutRange   [884 1242]
20. InMFLabels in1mf1
21.          in1mf2
22.          in2mf1
23.          in2mf2
24.          in3mf1
25.          in3mf2
26. OutMFLabels out1mf1
27.          out1mf2
28.          out1mf3
29.          out1mf4

```

Lampiran 20. Hasil dari Pemodelan ANFIS dengan *Gaussmf*
Menggunakan Matlab (Lanjutan)

```
30.      out1mf5
31.      out1mf6
32.      out1mf7
33.      out1mf8
34. InMFTypes    gaussmf
35.          gaussmf
36.          gaussmf
37.          gaussmf
38.          gaussmf
39.          gaussmf
40. OutMFTypes   linear
41.          linear
42.          linear
43.          linear
44.          linear
45.          linear
46.          linear
47.          linear
48. InMFParams   [220.2 847.7 0 0]
49.          [151.4 1141 0 0]
50.          [31.84 840.4 0 0]
51.          [46.32 1255 0 0]
52.          [101.2 903.9 0 0]
53.          [182 1235 0 0]
54. OutMFParams  [2.125 1.952 -2.626 -472]
55.          [-8.059 -0.7554 -3.054 1.239e+004]
56.          [-0.7327 -3.221 7.231 -955.7]
57.          [26.49 6.862 9.784 -4.049e+004]
58.          [1.66 -2.469 2.572 -933.4]
59.          [-2.241 3.36 3.052 -2385]
60.          [0.8889 2.493 -6.657 2679]
61.          [6.799 -4.76 -15.77 1.296e+004]
62. Rule Antecedent [1 1 1]
63.          [1 1 2]
64.          [1 2 1]
65.          [1 2 2]
66.          [2 1 1]
67.          [2 1 2]
68.          [2 2 1]
69.          [2 2 2]
62. Rule Consequent 1
63.          2
64.          3
65.          4
66.          5
```

Lampiran 20. Hasil dari Pemodelan ANFIS dengan *Gausmf*
Menggunakan Matlab (Lanjutan)

```
67.      6
68.      7
69.      8
62. Rule Weight    1
63.      1
64.      1
65.      1
66.      1
67.      1
68.      1
69.      1
62. Rule Connection 1
63.      1
64.      1
65.      1
66.      1
67.      1
68.      1
69.      1
>>
```

Lampiran 21. Program Pemodelan ANFIS dengan *Trapmf* Menggunakan Matlab

```
% memanggil data
x=load('d:/kertajaya.txt');

% input untuk data insample
xti_8=x(1:349);
xti_7=x(2:350);
xti_1=x(8:356);
% matriks
xti=[xti_8 xti_7 xti_1];

% input untuk data outsample
xto_8=x(350:363);
xto_7=x(351:364);
xto_1=x(357:370);
xto=[xto_8 xto_7 xto_1];

% target
y_i=x(9:357);
y_o=x(358:371);

% ANFIS
mfType='trapmf';
numMFs=2;
epoch_n=500
in_fis1=genfis1([xti y_i],numMFs,mfType);
out_fis1=anfis([xti y_i],in_fis1,epoch_n);

% Peramalan k-tahap ke depan
y_ihat=evalfis(xti,out_fis1)
yt=x;
for i=358:371;
    yt(i)=evalfis([yt(i-8) yt(i-7) yt(i-1)],out_fis1);
end
y_ohat=yt(358:371)

%residual
er_in=y_i-y_ihat;
er_out=y_o-y_ohat;
rmse_in=sqrt(sum(er_in.*er_in)/length(er_in))
rmse_out=sqrt(sum(er_out.*er_out)/length(er_out))
mape_in=sum(abs(er_in./y_i)/length(er_in))*100
mape_out=sum(abs(er_out./y_o)/length(er_out))*100
showfis(in_fis1)
showfis(out_fis1)
```

Lampiran 22. Hasil dari Pemodelan ANFIS dengan *Tapmf* Menggunakan Matlab

ANFIS info:

Number of nodes: 34
Number of linear parameters: 32
Number of nonlinear parameters: 24
Total number of parameters: 56
Number of training data pairs: 349
Number of checking data pairs: 0
Number of fuzzy rules: 8

Start training ANFIS ...

1 45.7643
2 45.7639
3 45.7636
4 45.7632
5 45.7629

Step size increases to 0.011000 after epoch 5.

:
:
496 44.8379
497 44.8385
498 44.8384

Step size decreases to 0.167562 after epoch 498.

499 44.84
500 44.8376

Designated epoch number reached --> ANFIS training completed at epoch 500.

y_ohat =
1.0e+003 *
0.9483
0.9487
1.0211
1.1169
0.9435
0.9447
0.9446
0.9575
0.9594
1.0085
1.0768
0.9685
0.9582
0.9574

Lampiran 22. Hasil dari Pemodelan ANFIS dengan *Trapmf* Menggunakan Matlab (Lanjutan)

```
rmse_in =
44.8376

rmse_out =
53.6389

mape_in =
3.2697

mape_out =
4.1935

1. Name      anfis
2. Type      sugeno
3. Inputs/Outputs [3 1]
4. NumInputMFs [2 2 2]
5. NumOutputMFs 8
6. NumRules    8
7. AndMethod   prod
8. OrMethod    max
9. ImpMethod   prod
10. AggMethod  max
11. DefuzzMethod wtaver
12. InLabels   input1
13.           input2
14.           input3
15. OutLabels  output
16. InRange    [884 1242]
17.           [884 1242]
18.           [884 1242]
19. OutRange   [884 1242]
20. InMFLabels in1mf1
21.           in1mf2
22.           in2mf1
23.           in2mf2
24.           in3mf1
25.           in3mf2
26. OutMFLabels out1mf1
27.           out1mf2
28.           out1mf3
29.           out1mf4
30.           out1mf5
31.           out1mf6
32.           out1mf7
33.           out1mf8
```

Lampiran 22. Hasil dari Pemodelan ANFIS dengan *Trapmf* Menggunakan Matlab (Lanjutan)

```

34. InMFTypes trapmf
35. trapmf
36. trapmf
37. trapmf
38. trapmf
39. trapmf
40. OutMFTypes linear
41. linear
42. linear
43. linear
44. linear
45. linear
46. linear
47. linear
48. InMFParams [633.4 776.6 978.4 1123]
49. [989 1121 1349 1493]
50. [633.4 776.6 987 1120]
51. [991.1 1130 1349 1493]
52. [633.4 776.6 983 1124]
53. [1026 1123 1349 1493]
54. OutMFParams [0.02238 0.4898 0.08439 392.7]
55. [-2.038 3.233 -0.9234 959.6]
56. [0.1801 -0.4311 1.906 -504.4]
57. [16.64 9.029 1.169 -2.67e+004]
58. [0.3507 -0.03754 -0.04044 670.7]
59. [-1.376 -0.1252 0.6838 1887]
60. [-0.342 0.5345 -0.01499 724.4]
61. [8.694 -11.62 -23.17 2.835e+004]
62. Rule Antecedent [1 1 1]
63. [1 1 2]
64. [1 2 1]
65. [1 2 2]
66. [2 1 1]
67. [2 1 2]
68. [2 2 1]
69. [2 2 2]
62. Rule Consequent 1
63. 2
64. 3
65. 4
66. 5
67. 6
68. 7
69. 8

```

Lampiran 22. Hasil dari Pemodelan ANFIS dengan *Trapmf* Menggunakan Matlab (Lanjutan)

```
62. Rule Weight    1
63.          1
64.          1
65.          1
66.          1
67.          1
68.          1
69.          1
62. Rule Connection 1
63.          1
64.          1
65.          1
66.          1
67.          1
68.          1
69.          1
1. Name      anfis
2. Type      sugeno
3. Inputs/Outputs [3 1]
4. NumInputMFs [2 2 2]
5. NumOutputMFs 8
6. NumRules     8
7. AndMethod    prod
8. OrMethod     max
9. ImpMethod    prod
10. AggMethod   max
11. DefuzzMethod wtaver
12. InLabels    input1
13.          input2
14.          input3
15. OutLabels   output
16. InRange     [884 1242]
17.          [884 1242]
18.          [884 1242]
19. OutRange    [884 1242]
20. InMFLabels  in1mf1
21.          in1mf2
22.          in2mf1
23.          in2mf2
24.          in3mf1
25.          in3mf2
26. OutMFLabels out1mf1
27.          out1mf2
28.          out1mf3
29.          out1mf4
```

Lampiran 22. Hasil dari Pemodelan ANFIS dengan *Trapmf*
Menggunakan Matlab (Lanjutan)

```

30.      out1mf5
31.      out1mf6
32.      out1mf7
33.      out1mf8
34. InMFTypes    trapmf
35.      trapmf
36.      trapmf
37.      trapmf
38.      trapmf
39.      trapmf
40. OutMFTypes   linear
41.      linear
42.      linear
43.      linear
44.      linear
45.      linear
46.      linear
47.      linear
48. InMFParams   [633.4 776.6 978.4 1123]
49.      [989 1121 1349 1493]
50.      [633.4 776.6 987 1120]
51.      [991.1 1130 1349 1493]
52.      [633.4 776.6 983 1124]
53.      [1026 1123 1349 1493]
54. OutMFParams  [0.02238 0.4898 0.08439 392.7]
55.      [-2.038 3.233 -0.9234 959.6]
56.      [0.1801 -0.4311 1.906 -504.4]
57.      [16.64 9.029 1.169 -2.67e+004]
58.      [0.3507 -0.03754 -0.04044 670.7]
59.      [-1.376 -0.1252 0.6838 1887]
60.      [-0.342 0.5345 -0.01499 724.4]
61.      [8.694 -11.62 -23.17 2.835e+004]
62. Rule Antecedent [1 1 1]
63.      [1 1 2]
64.      [1 2 1]
65.      [1 2 2]
66.      [2 1 1]
67.      [2 1 2]
68.      [2 2 1]
69.      [2 2 2]
62. Rule Consequent 1
63.      2
64.      3
65.      4
66.      5

```

Lampiran 22. Hasil dari Pemodelan ANFIS dengan *Trapmf*
Menggunakan Matlab (Lanjutan)

67.	6
68.	7
69.	8
62. Rule Weight	1
63.	1
64.	1
65.	1
66.	1
67.	1
68.	1
69.	1
62. Rule Connection	1
63.	1
64.	1
65.	1
66.	1
67.	1
68.	1
69.	1

Lampiran 23. Program Pemodelan ANFIS dengan *Trimf* Menggunakan Matlab

```
% memanggil data
x=load('d:/kertajaya.txt');

% input untuk data insample
xti_8=x(1:349);
xti_7=x(2:350);
xti_1=x(8:356);
% matriks
xti=[xti_8 xti_7 xti_1];

% input untuk data outsample
xto_8=x(350:363);
xto_7=x(351:364);
xto_1=x(357:370);
xto=[xto_8 xto_7 xto_1];

% target
y_i=x(9:357);
y_o=x(358:371);

% ANFIS
mfType='trimf';
numMFs=2;
epoch_n=500
in_fis1=genfis1([xti y_i],numMFs,mfType);
out_fis1=anfis([xti y_i],in_fis1,epoch_n);

% Peramalan k-tahap ke depan
y_ihat=evalfis(xti,out_fis1)
yt=x;
for i=358:371;
    yt(i)=evalfis([yt(i-8) yt(i-7) yt(i-1)],out_fis1);
end
y_ohat=yt(358:371)

%residual
er_in=y_i-y_ihat;
er_out=y_o-y_ohat;
rmse_in=sqrt(sum(er_in.*er_in)/length(er_in))
rmse_out=sqrt(sum(er_out.*er_out)/length(er_out))
mape_in=sum(abs(er_in./y_i)/length(er_in))*100
mape_out=sum(abs(er_out./y_o)/length(er_out))*100
showfis(in_fis1)
showfis(out_fis1)
```

Lampiran 24. Hasil dari Pemodelan ANFIS dengan *Trimf* Menggunakan Matlab

ANFIS info:

```
Number of nodes: 34
Number of linear parameters: 32
Number of nonlinear parameters: 18
Total number of parameters: 50
Number of training data pairs: 349
Number of checking data pairs: 0
Number of fuzzy rules: 8
```

Start training ANFIS ...

```
1      47.0895
2      47.037
3      46.9632
4      46.9585
5      46.9473
```

Step size increases to 0.011000 after epoch 5.

```
:
:
496    46.9326
497    46.9326
```

Step size decreases to 0.000089 after epoch 497.

```
498    46.9326
499    46.9326
500    46.9326
```

Designated epoch number reached --> ANFIS training completed at epoch 500.

```
y_ohat =
1.0e+003 *
0.9429
0.9740
1.0205
1.0671
0.8976
0.9182
0.9299
0.9519
0.9774
1.0076
1.0437
0.8971
0.9078
0.9331
```

Lampiran 24. Hasil dari Pemodelan ANFIS dengan *Trimf* Menggunakan Matlab (Lanjutan)

```
rmse_in =  
46.9326  
  
rmse_out =  
51.8971  
  
mape_in =  
3.4160  
  
mape_out =  
3.8121  
1. Name      anfis  
2. Type       sugeno  
3. Inputs/Outputs [3 1]  
4. NumInputMFs [2 2 2]  
5. NumOutputMFs 8  
6. NumRules    8  
7. AndMethod   prod  
8. OrMethod    max  
9. ImpMethod   prod  
10. AggMethod  max  
11. DefuzzMethod wtaver  
12. InLabels   input1  
13.           input2  
14.           input3  
15. OutLabels  output  
16. InRange    [884 1242]  
17.           [884 1242]  
18.           [884 1242]  
19. OutRange   [884 1242]  
20. InMFLabels in1mf1  
21.           in1mf2  
22.           in2mf1  
23.           in2mf2  
24.           in3mf1  
25.           in3mf2  
26. OutMFLabels out1mf1  
27.           out1mf2  
28.           out1mf3  
29.           out1mf4  
30.           out1mf5  
31.           out1mf6  
32.           out1mf7  
33.           out1mf8
```

Lampiran 24. Hasil dari Pemodelan ANFIS dengan *Trimf* Menggunakan Matlab (Lanjutan)

```
34. InMFTypes trimf
35.      trimf
36.      trimf
37.      trimf
38.      trimf
39.      trimf
40. OutMFTypes linear
41.      linear
42.      linear
43.      linear
44.      linear
45.      linear
46.      linear
47.      linear
48. InMFParams [526 884 1242 0]
49.          [884 1242 1600 0]
50.          [526 884 1242 0]
51.          [884 1242 1600 0]
52.          [526 884 1242 0]
53.          [884 1242 1600 0]
54. OutMFParams [0 0 0 0]
55.          [0 0 0 0]
56.          [0 0 0 0]
57.          [0 0 0 0]
58.          [0 0 0 0]
59.          [0 0 0 0]
60.          [0 0 0 0]
61.          [0 0 0 0]
62. Rule Antecedent [1 1 1]
63.          [1 1 2]
64.          [1 2 1]
65.          [1 2 2]
66.          [2 1 1]
67.          [2 1 2]
68.          [2 2 1]
69.          [2 2 2]
62. Rule Consequent 1
63.          2
64.          3
65.          4
66.          5
67.          6
68.          7
69.          8
```

Lampiran 24. Hasil dari Pemodelan ANFIS dengan *Trimf*
Menggunakan Matlab (Lanjutan)

```

62. Rule Weight    1
63.      1
64.      1
65.      1
66.      1
67.      1
68.      1
69.      1
62. Rule Connection 1
63.      1
64.      1
65.      1
66.      1
67.      1
68.      1
69.      1
1. Name      anfis
2. Type      sugeno
3. Inputs/Outputs [3 1]
4. NumInputMFs [2 2 2]
5. NumOutputMFs 8
6. NumRules   8
7. AndMethod  prod
8. OrMethod   max
9. ImpMethod  prod
10. AggMethod max
11. DefuzzMethod wtaver
12. InLabels   input1
13.          input2
14.          input3
15. OutLabels  output
16. InRange    [884 1242]
17.          [884 1242]
18.          [884 1242]
19. OutRange   [884 1242]
20. InMFLabels in1mf1
21.          in1mf2
22.          in2mf1
23.          in2mf2
24.          in3mf1
25.          in3mf2
26. OutMFLabels out1mf1
27.          out1mf2
28.          out1mf3
29.          out1mf4

```

Lampiran 24. Hasil dari Pemodelan ANFIS dengan *Trimf* Menggunakan Matlab (Lanjutan)

```
30.      out1mf5
31.      out1mf6
32.      out1mf7
33.      out1mf8
34. InMFTypes    trimf
35.      trimf
36.      trimf
37.      trimf
38.      trimf
39.      trimf
40. OutMFTypes   linear
41.      linear
42.      linear
43.      linear
44.      linear
45.      linear
46.      linear
47.      linear
48. InMFParams   [526 884 1242 0]
49.      [884 1242 1600 0]
50.      [526 884 1242 0]
51.      [884 1242 1600 0]
52.      [526 884 1242 0]
53.      [884.1 1242 1600 0]
54. OutMFParams  [-1061 353 714.9 -5335]
55.      [-764 -244.4 716.2 3797]
56.      [-916.1 350.2 420.4 3794]
57.      [-248.5 -235.6 415.9 -2703]
58.      [-1061 1036 451.2 3795]
59.      [-761.3 437.6 452.6 -2704]
60.      [-917.2 1040 -168.2 -2702]
61.      [-252.4 423.6 -174 1923]
62. Rule Antecedent [1 1 1]
63.      [1 1 2]
64.      [1 2 1]
65.      [1 2 2]
66.      [2 1 1]
67.      [2 1 2]
68.      [2 2 1]
69.      [2 2 2]
62. Rule Consequent 1
63.      2
64.      3
65.      4
66.      5
```

Lampiran 24. Hasil dari Pemodelan ANFIS dengan *Trimf*
Menggunakan Matlab (Lanjutan)

67.	6
68.	7
69.	8
62. Rule Weight	1
63.	1
64.	1
65.	1
66.	1
67.	1
68.	1
69.	1
62. Rule Connection	1
63.	1
64.	1
65.	1
66.	1
67.	1
68.	1
69.	1

Lampiran 25. Program Pemodelan ANFIS dengan *Pimf* Menggunakan Matlab

```
% memanggil data
x=load('d:/kertajaya.txt');

% input untuk data insample
xti_8=x(1:349);
xti_7=x(2:350);
xti_1=x(8:356);
% matriks
xti=[xti_8 xti_7 xti_1];

% input untuk data outsample
xto_8=x(350:363);
xto_7=x(351:364);
xto_1=x(357:370);
xto=[xto_8 xto_7 xto_1];

% target
y_i=x(9:357);
y_o=x(358:371);

% ANFIS
mfType='pimf';
numMFs=2;
epoch_n=500
in_fis1=genfis1([xti y_i],numMFs,mfType);
out_fis1=anfis([xti y_i],in_fis1,epoch_n);

% Peramalan k-tahap ke depan
y_ihat=evalfis(xti,out_fis1)
yt=x;
for i=358:371;
    yt(i)=evalfis([yt(i-8) yt(i-7) yt(i-1)],out_fis1);
end
y_ohat=yt(358:371)

%residual
er_in=y_i-y_ihat;
er_out=y_o-y_ohat;
rmse_in=sqrt(sum(er_in.*er_in)/length(er_in))
rmse_out=sqrt(sum(er_out.*er_out)/length(er_out))
mape_in=sum(abs(er_in./y_i)/length(er_in))*100
mape_out=sum(abs(er_out./y_o)/length(er_out))*100
showfis(in_fis1)
showfis(out_fis1)
```

Lampiran 26. Hasil Pemodelan ANFIS dengan *Pimf* Menggunakan Matlab

ANFIS info:

Number of nodes: 34
Number of linear parameters: 32
Number of nonlinear parameters: 24
Total number of parameters: 56
Number of training data pairs: 349
Number of checking data pairs: 0
Number of fuzzy rules: 8

Start training ANFIS ...

1 45.6803
2 45.6801
3 45.6799
4 45.6798
5 45.6797

Step size increases to 0.011000 after epoch 5.

:
:
496 43.4941
497 43.4934
498 43.4935
499 43.4934

Step size decreases to 0.415325 after epoch 499.

500 43.4924

Designated epoch number reached --> ANFIS training completed at epoch 500.

```
y_ohat =  
1.0e+003 *  
0.9473  
0.9872  
0.9929  
1.1055  
0.9224  
0.9408  
0.9425  
0.9568  
0.9816  
0.9889  
1.1022  
0.9349  
0.9525  
0.9557
```

Lampiran 26. Hasil dari Pemodelan ANFIS dengan *Pimf* Menggunakan Matlab (Lanjutan)

```
rmse_in =  
43.4924  
  
rmse_out =  
51.2986  
  
mape_in =  
3.1986  
  
mape_out =  
3.8104  
  
1. Name      anfis  
2. Type      sugeno  
3. Inputs/Outputs [3 1]  
4. NumInputMFs [2 2 2]  
5. NumOutputMFs 8  
6. NumRules    8  
7. AndMethod   prod  
8. OrMethod    max  
9. ImpMethod   prod  
10. AggMethod  max  
11. DefuzzMethod wtaver  
12. InLabels   input1  
13.           input2  
14.           input3  
15. OutLabels  output  
16. InRange    [884 1242]  
17.           [884 1242]  
18.           [884 1242]  
19. OutRange   [884 1242]  
20. InMFLabels in1mf1  
21.           in1mf2  
22.           in2mf1  
23.           in2mf2  
24.           in3mf1  
25.           in3mf2  
26. OutMFLabels out1mf1  
27.           out1mf2  
28.           out1mf3  
29.           out1mf4  
30.           out1mf5  
31.           out1mf6  
32.           out1mf7  
33.           out1mf8
```

Lampiran 26. Hasil dari Pemodelan ANFIS dengan *Pimf* Menggunakan Matlab (Lanjutan)

```

34. InMFTypes    pimf
35.          pimf
36.          pimf
37.          pimf
38.          pimf
39.          pimf
40. OutMFTypes   linear
41.          linear
42.          linear
43.          linear
44.          linear
45.          linear
46.          linear
47.          linear
48. InMFParams   [633.4 776.6 991.4 1135]
49.          [991.4 1135 1349 1493]
50.          [633.4 776.6 991.4 1135]
51.          [991.4 1135 1349 1493]
52.          [633.4 776.6 991.4 1135]
53.          [991.4 1135 1349 1493]
54. OutMFParams  [0 0 0 0]
55.          [0 0 0]
56.          [0 0 0]
57.          [0 0 0]
58.          [0 0 0]
59.          [0 0 0]
60.          [0 0 0]
61.          [0 0 0]
62. Rule Antecedent [1 1 1]
63.          [1 1 2]
64.          [1 2 1]
65.          [1 2 2]
66.          [2 1 1]
67.          [2 1 2]
68.          [2 2 1]
69.          [2 2 2]
62. Rule Consequent 1
63.          2
64.          3
65.          4
66.          5
67.          6
68.          7
69.          8

```

Lampiran 26. Hasil dari Pemodelan ANFIS dengan *Piimf* Menggunakan Matlab (Lanjutan)

```
62. Rule Weight    1
63.          1
64.          1
65.          1
66.          1
67.          1
68.          1
69.          1
62. Rule Connection 1
63.          1
64.          1
65.          1
66.          1
67.          1
68.          1
69.          1
1. Name      anfis
2. Type      sugeno
3. Inputs/Outputs [3 1]
4. NumInputMFs [2 2 2]
5. NumOutputMFs 8
6. NumRules     8
7. AndMethod    prod
8. OrMethod     max
9. ImpMethod    prod
10. AggMethod   max
11. DefuzzMethod wtaver
12. InLabels    input1
13.          input2
14.          input3
15. OutLabels   output
16. InRange     [884 1242]
17.          [884 1242]
18.          [884 1242]
19. OutRange    [884 1242]
20. InMFLabels  in1mf1
21.          in1mf2
22.          in2mf1
23.          in2mf2
24.          in3mf1
25.          in3mf2
26. OutMFLabels out1mf1
27.          out1mf2
28.          out1mf3
29.          out1mf4
```

Lampiran 26. Hasil dari Pemodelan ANFIS dengan *Pimf* Menggunakan Matlab (Lanjutan)

```

30.      out1mf5
31.      out1mf6
32.      out1mf7
33.      out1mf8
34. InMFTypes    pimf
35.          pimf
36.          pimf
37.          pimf
38.          pimf
39.          pimf
40. OutMFTypes   linear
41.          linear
42.          linear
43.          linear
44.          linear
45.          linear
46.          linear
47.          linear
48. InMFParams   [633.4 776.6 1044 1045]
49.          [997.6 1150 1349 1493]
50.          [633.4 776.6 1076 1088]
51.          [985 1179 1349 1493]
52.          [633.4 776.6 938.6 1130]
53.          [1038 1039 1349 1493]
54. OutMFParams  [0.03436 0.565 0.09353 301.9]
55.          [-1.457 1.284 -0.4264 1692]
56.          [0.1964 -0.03001 2.405 -1438]
57.          [5.057 6.22 -5.807 -4779]
58.          [0.1527 0.1866 0.04803 580.1]
59.          [-0.3428 1.266 0.2507 -131.4]
60.          [0.05594 0.4698 0.8946 -520.4]
61.          [-3.878 -2.854 -19.18 2.855e+004]
62. Rule Antecedent [1 1 1]
63.          [1 1 2]
64.          [1 2 1]
65.          [1 2 2]
66.          [2 1 1]
67.          [2 1 2]
68.          [2 2 1]
69.          [2 2 2]
62. Rule Consequent 1
63.          2
64.          3
65.          4
66.          5

```

Lampiran 26. Hasil dari Pemodelan ANFIS dengan *Trimf* Menggunakan Matlab (Lanjutan)

67.	6
68.	7
69.	8
62. Rule Weight	1
63.	1
64.	1
65.	1
66.	1
67.	1
68.	1
69.	1
62. Rule Connection	1
63.	1
64.	1
65.	1
66.	1
67.	1
68.	1
69.	1

Halaman ini sengaja dikosongkan

BIODATA PENULIS



Ilafi Andalita dilahirkan di Jember, 23 Januari 1993 dari pasangan yang penuh kasih sayang Nurmanto dan Purwaningsih. Pendidikan formal ditempuh Penulis di SDN 1 Tanjungsari, SMPN 1 Umbulsari, dan SMAN 1 Jember. Tahun 2011, Penulis dihadapkan pada perjuangan dalam seleksi Akademi Kepolisian dan jalur undangan ke Perguruan Tinggi ITS. Perjuangan tersebut diakhiri dengan diterimanya Penulis men-

jadi Mahasiswa Statistika FMIPA ITS dengan identitas NRP 1311 100 038. Selama menempuh bangku perkuliahan Penulis diberikan kesempatan untuk berprestasi dalam bidang PKM-P terdanai dikti tahun 2014 dan 2015 bersama Tim. Selain itu, amanah yang diberikan oleh organisasi kemahasiswaan adalah staf DAGRI HIMASTA-ITS dan staf PSDM BEM-ITS (2012/2013), Kadep DAGRI HIMASTA-ITS (2013/2014), pemandu aktif ITS (2012/2015), serta sebagai pengajar di IECC dan kepanitiaan. Ketertarikan Penulis dalam bidang analisis *time series* ditunjukkan melalui penelitian Tugas Akhir yang berjudul “Peramalan Jumlah Penumpang Kereta Api Kelas Ekonomi Kertaajaya Menggunakan ARIMA dan ANFIS”. Harapan Penulis terhadap masa mendatang adalah setiap kita memiliki *sense* terhadap aplikasi statistik semakin meningkat tidak hanya statistikawan ataupun akademisi namun masyarakat luas. Apabila terdapat keinginan berdiskusi berhubungan dengan Tugas Akhir Penulis, maka dapat menghubungi melalui ilafilita@gmail.com.