



THESIS - SS142501

**FORECASTING ON INDONESIA'S FISHERY EXPORT
USING ARIMA, FEED FORWARD NEURAL NETWORK,
AND WEIGHTED FUZZY TIME SERIES**

**EUNIKE WIDYA PARAMESWARI
NRP. 1314201706**

SUPERVISORS

**Dr. Brodjol Sutijo Suprih Ulama, M.Si
Dr. Suhartono, S.Si, M.Sc**

**MAGISTER PROGRAM
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUTE OF TECHNOLOGY SEPULUH NOPEMBER
SURABAYA
2016**



TESIS - SS142501

**PERAMALAN EKSPOR PERIKANAN INDONESIA
DENGAN PENDEKATAN ARIMA, *FEED FORWARD
NEURAL NETWORK*, DAN *WEIGHTED FUZZY
TIME SERIES***

**EUNIKE WIDYA PARAMESWARI
NRP. 1314201706**

**DOSEN PEMBIMBING
Dr. Brodjol Sutijo Suprih Ulama, M.Si
Dr. Suhartono, S.Si, M.Sc**

**PROGRAM MAGISTER
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2016**


**PERAMALAN EKSPOR PERIKANAN INDONESIA DENGAN PENDEKATAN
ARIMA, FEED FORWARD NEURAL NETWORK, DAN WEIGHTED FUZZY TIME
SERIES**

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Sains (M.Si)
di
Institut Teknologi Sepuluh Nopember
Oleh:

EUNIKE WIDYA PARAMESWARI
NRP: 1314 201 706

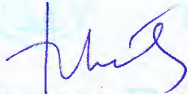
Disetujui Oleh

Tanggal Ujian : 22 Januari 2016
Periode Wisuda : Maret 2016


1. Dr. Brodjol Sutijo Suprih Ulama, M.Si (Pembimbing I)
NIP: 19660125 199002 1 001


2. Dr. Suhartono, S.Si, M.Sc (Pembimbing II)
NIP: 19710929 199512 1 001


3. Dr. Rer.pol. Heri Kuswanto, S.Si, M.Si (Penguji)
NIP: 19820326 200312 1 004


4. Irhamah, M.Si, Ph.D (Penguji)
NIP: 19780406 200112 2 002


5. Dr. Erni Tri Astuti, M.Math (Penguji)
NIP: 19671022 199003 2 002



DAFTAR GAMBAR


No	Judul	Halaman
2.1	Tahapan ARIMA	16
2.2	Grafik Fungsi Linier	24
2.3	Grafik Fungsi Treshold	25
2.4	Grafik Sigmoid Biner	25
2.5	Grafik Sigmoid Bipolar	26
3.1	Diagram alir metode ARIMA melalui prosedur Box-Jenkins	47
3.2	Diagram alir metode FFNN	48
3.3	Diagram alir metode Hibrida ARIMA-NN	49
4.1	Rata-rata bulanan volume ekspor perikanan Indonesia	51
4.2	Box Plot untuk rata-rata bulanan volume ekspor perikanan Indonesia	52
4.3	Kontribusi masing-masing kelompok komoditi terhadap ekspor Perikanan	52
4.4	Perkembangan ekspor perikanan Indonesia untuk komoditi unggulan	53
4.5	Plot data training volume ekspor perikanan kelompok komoditi 302	54
4.6	Box-Cox plot untuk kelompok komoditi 302	54
4.7	Plot data dan pola ACF, PACF sesudah transformasi	55
4.8	Perbandingan hasil peramalan dan nilai aktual dari outsample pada kelompok komoditi 302	57
4.9	Plot data volume ekspor perikanan kelompok komoditi 302 beserta peramalan 12 bulan berikutnya	58
4.10	Perbandingan hasil peramalan WFTS pada kelompok komoditi 302	67
4.11	Perbandingan hasil peramalan pada kelompok komoditi 302	67
4.12	Plot data training volume ekspor perikanan kelompok komoditi 303	68
4.13	Box Cox plot untuk kelompok komoditi 303	68
4.14	Plot data training setelah transformasi ln	69
4.15	Box Cox plot setelah transformasi ln	69
4.16	Plot data training, ACF, dan PACF kelompok komoditi 303 setelah	70

	transformasi	
4.17	Perbandingan hasil ramalan dengan nilai aktual pada outsample untuk kelompok komoditi 303	74
4.18	Peramalan 12 bulan berikutnya dari kelompok komoditi 303	75
4.19	Perbandingan hasil peramalan WFTS pada kelompok komoditi 303	85
4.20	Perbandingan hasil peramalan pada kelompok komoditi 303	86
4.21	Plot data training kelompok komoditi 306	86
4.22	Box Cox plot untuk kelompok komoditi 306	87
4.23	Plot data dan pola ACF, PACF sesudah transformasi	88
4.24	Peramalan 12 bulan berikutnya pada kelompok komoditi 306	90
4.25	Arsitektur NN(1;2;1) untuk kelompok komoditi 306	92
4.26	Perbandingan hasil peramalan seluruh metode peramalan	97

DAFTAR LAMPIRAN

No	Judul	Halaman
1	Volume ekspor perikanan Indonesia periode Januari 1999 – Juli 2015 kelompok komoditi 302	109
2	Volume ekspor perikanan Indonesia periode Januari 1999 – Juli 2015 kelompok komoditi 303	111
3	Volume ekspor perikanan Indonesia periode Januari 1999 – Juli 2015 kelompok komoditi 306	113
4	Output Program SAS untuk Model ARIMA (1,0,1) pada kelompok komoditi 302	115
5	Output Program SAS untuk Model ARIMA (2,0,0) (0,0,1) ¹² tanpa deteksi outlier pada kelompok komoditi 303	116
6	Output Program SAS untuk Model ARIMA (2,0,0) (0,0,1) ¹² dengan deteksi outlier pada kelompok komoditi 303	117
7	Output Program SAS untuk Model ARIMA (1,0,[1,10]) pada kelompok komoditi 306	118
8	Syntax Program SAS untuk Model ARIMA (1,0,1) pada kelompok komoditi 302	119
9	Syntax Program SAS untuk Model ARIMA (2,0,0)(0,0,1) ¹² pada kelompok komoditi 303	120
10	Syntax Program SAS untuk Model ARIMA (1,0,[1,10]) pada kelompok komoditi 306	121
11	Syntax program Matlab untuk peramalan FFNN dan Hibrida ARIMA-NN pada kelompok komoditi 302	122
12	Syntax program Matlab untuk peramalan FFNN dan Hibrida ARIMA-NN pada kelompok komoditi 303	123
13	Syntax program Matlab untuk peramalan FFNN dan Hibrida ARIMA-NN pada kelompok komoditi 306	126
14	Perbandingan Hasil Peramalan pada Kelompok Komoditi 302	128

15	Perbandingan Hasil Peramalan pada Kelompok Komoditi 303	129
16	Perbandingan Hasil Peramalan pada Kelompok Komoditi 306	130
17	Perbandingan Kinerja Peramalan masing-masing kelompok komoditi	131



KATA PENGANTAR

Terpujilah Allah, sumber segala hikmat, yang di dalam Kristus Yesus telah menjadi dasar dari segala pengharapan, serta Roh Kudus yang senantiasa mengaruniakan damai sejahtera yang melampaui segala akal sehingga penulis dapat menyelesaikan tesis dengan judul “**Peramalan Ekspor Perikanan Indonesia dengan Pendekatan ARIMA, *Feed Forward Neural Network*, dan *Weighted Fuzzy Time Series***”. Tesis ini merupakan hasil penelitian yang diajukan sebagai salah satu syarat untuk memperoleh gelar Magister Sains (M.Si) pada Program Studi Magister Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Institut Teknologi Sepuluh Nopember Surabaya.

Semua hal yang telah dicapai dan diselesaikan tidak terlepas dari bimbingan, arahan, petunjuk, dorongan moril maupun bantuan materi dari berbagai pihak. Oleh karena itu penulis mengucapkan terima kasih yang tak terhingga dan penghargaan yang sebesar-besarnya kepada:

1. Bapak Dr. Brodjol Sutijo Suprih Ulama, M.Sc selaku pembimbing utama dan Bapak Dr. Suhartono, M.Sc selaku co pembimbing yang telah begitu luar biasa menyediakan waktu dan kesempatan untuk mengoreksi, mengarahkan, membimbing, bahkan memberikan dorongan semangat bagi penulis.
2. Bapak Dr. Rer. Pol Heri Kuswanto, M.Si, Ibu Irhamah, M.Si, Ph.D, dan Ibu Dr. Erni Tri Astuti, M.Math selaku dosen penguji atas setiap masukan dan saran bagi penyempurnaan tesis ini.
3. Kepala Badan Pusat Statistik RI dan Kepala BPS Provinsi Nusa Tenggara Timur, yang telah memberi kesempatan kepada penulis untuk melanjutkan studi pada Program Studi Magister Statistika FMIPA ITS Surabaya.
4. Bapak/Ibu Dosen pengajar Jurusan Statistika FMIPA ITS Surabaya yang telah memberikan dan mengajarkan ilmunya kepada penulis.
5. Kedua orang tuaku yang tercinta, Bapak Tjipto Rahardjo dan Ibu Elizabeth Setyo Rahayu, serta kedua saudariku, Hanna Widya Pramandari dan Prita

Dewi Maharani, atas segala doa dan dukungan yang selalu membuat penulis merasa bersyukur dilahirkan dalam keluarga yang selalu penuh dengan kehangatan cinta dan kasih ini. Tak lupa menyebutkan ketiga keponakanku Rebecca, Raphael (alm), dan Renatha yang dalam keluguan dan kepolosan telah menghadirkan sukacita yang tak terhingga bagi penulis.

6. Saudari-saudariku di ARH 48, Widi, Mpih, Santi, Yani, Dian, dan Yanti atas persahabatan dan persaudaraan yang tulus selama 18 bulan. Semua hal yang telah dilalui dalam kebersamaan, baik canda tawa bahkan keluh kesah dan air mata sungguh tak ternilai harganya. Suatu hari kelak jangan pernah remehkan bahkan 'secuil' rasa rindu.
7. Sahabat, kakak, dan saudaraku, Kak Node. Syukur kepada Allah, yang telah mengirim kakak ke Surabaya. Sungguh tak ada yang kebetulan. Terima kasih tak terhingga untuk segalanya.
8. Teman-teman seperjuangan (kelas Magister BPS angkatan ke-8): Mas Ali, Mas Muryanto, Bang Henry, Mas Duto, Arip, Anita, Zablin, Afni, Rory, Aan, Fatih, Vivin, dan Maul atas kebersamaan selama 18 bulan yang telah memberikan pengalaman dan pelajaran kehidupan yang sangat berharga.
9. Saudara-saudara seiman dari GBI Imamat Rajani, secara khusus anggota komsel, Ce Eny, Ko Fendi, dkk atas doanya yang tulus, serta seluruh keluarga besar GBI Kalvari Misi, Atambua, secara khusus Papi dan Mami selaku orangtua rohani yang tetap memberikan doa dalam iman yang luar biasa.
10. Teman-teman kelas BPS angkatan ke-9, serta seluruh pihak dan kerabat yang tak dapat disebutkan satu per satu yang juga telah memberikan kontribusi bagi penyusunan tesis ini.

Kiranya Tuhan membalas segala kebaikan yang penulis terima, dan kiranya tesis ini dapat memberikan sumbangan yang berarti bagi semua pihak yang berkepentingan.

Surabaya, Januari 2016

Penulis

PERAMALAN EKSPOR PERIKANAN INDONESIA DENGAN PENDEKATAN ARIMA, *FEED FORWARD NEURAL NETWORK* DAN *WEIGHTED FUZZY TIME SERIES*

Nama Mahasiswa : Eunike Widya Parameswari
NRP : 1314201706
Pembimbing : Dr. Brodjol Sutijo Suprih Ulama, M.Si
Dr. Suhartono, S.Si, M.Sc

ABSTRAK

Salah satu indikator untuk memonitor peningkatan perdagangan internasional adalah dengan memperhatikan pertumbuhan ekspor. Peningkatan kinerja ekspor mempunyai dampak langsung dalam meningkatkan pertumbuhan ekonomi. Hal ini berarti ekspor memiliki dampak langsung terhadap perekonomian suatu negara. Ketersediaan data ekspor sangat penting bagi pengambilan keputusan dan kebijakan perdagangan luar negeri oleh pemerintah. Berdasarkan klasifikasi komoditi, salah satu sektor yang memberikan kontribusi cukup besar terhadap volume ekspor Indonesia adalah perikanan. Ketersediaan data volume ekspor terkini menjadi tantangan dalam mengaplikasikan metode peramalan yang efektif. Pada awalnya, metode peramalan didominasi oleh metode linier. Namun demikian, metode linier tidak dapat menangkap hubungan non-linier yang seringkali dijumpai pada kondisi riil. Tujuan dari penelitian ini adalah untuk meramalkan volume ekspor perikanan Indonesia dengan metode linier serta non-linier. Metode linier yang digunakan adalah ARIMA, sedangkan metode non-linier yang digunakan adalah *Feed Forward Neural Network* (FFNN) dan *Weighted Fuzzy Time Series* (WFTS). FFNN merupakan arsitektur NN yang sering diaplikasikan dalam berbagai bidang. Metode ARIMA digunakan untuk mendapatkan arsitektur NN yang paling sesuai sehingga dapat diperoleh model NN dengan kinerja peramalan terbaik. Hasil empiris dari penelitian ini menunjukkan bahwa metode WFTS unggul dalam peramalan pada kelompok komoditi 302 dan 306. Sedangkan metode Hibrida ARIMA-NN menunjukkan kinerja yang terbaik pada peramalan untuk kelompok komoditi 303.

Kata kunci: ekspor, Neural Network, *Weighted Fuzzy Time Series*, ARIMA

FORECASTING ON INDONESIA'S FISHERY EXPORT USING ARIMA, FEED FORWARD NEURAL NETWORK, AND WEIGHTED FUZZY TIME SERIES

Name : Eunike Widya Parameswari
NRP : 1314201706
Supervisors : Dr. Brodjol Sutijo Suprih Ulama, M.Si
Dr. Suhartono, S.Si, M.Sc

ABSTRACT

One of the indicators to monitor the increase in international trade is by paying attention to the export growth. Improved export performance has a direct impact in promoting economic growth. This means that exports have a direct impact on the economy of a country. Export data availability is critical for decision-making and foreign trade policy by the government. Based on the classification of commodities, one of the sectors that make a significant contribution to the Indonesian export volume is fisheries. Current export volume of data availability is a challenge in applying an effective forecasting method. At first, the method of forecasting is dominated by linear methods. However, the linear method can not capture non-linear relationships that are often found in real conditions. The aim of this study is to predict the volume of Indonesian fisheries exports to the method of linear and non-linear. Linear methods used are ARIMA, whereas non-linear method used is Feed Forward Neural Network (FFNN) and Weighted Fuzzy Time Series (WFTS). FFNN is an NN architecture that is often applied in various fields. ARIMA method used to obtain the most suitable NN architecture so as to obtain NN models with the best forecasting performance. The empirical results of this study indicate that the method WFTS outperforms in forecasting the commodity groups of 302 and 306. While hybrid ARIMA-NN method showed the best performance in forecasting for 303 commodity groups.

Keywords: *export, Neural Network, Weighted Fuzzy Time Series , ARIMA*

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Dalam perspektif makro ekonomi, perekonomian internasional merupakan suatu studi yang dipandang semakin penting. Kalangan pengusaha, konsumen, dan pemerintah semakin menyadari bahwa hidup mereka tidak hanya dipengaruhi oleh apa yang terjadi di kota atau negara mereka sendiri, melainkan juga apa yang terjadi di seluruh dunia (Mankiw, 2009). Perdagangan internasional telah menjadi elemen utama dari integrasi peningkatan perdagangan, keuangan, orang, dan ide-ide dalam suatu pasar global, atau disebut juga globalisasi.

Globalisasi lebih formal mengacu pada perubahan ekonomi, sosial, budaya, atau lingkungan yang cenderung menghubungkan orang-orang di seluruh dunia. Bukti empiris menunjukkan bahwa globalisasi telah secara signifikan meningkatkan pertumbuhan ekonomi di negara-negara berkembang.

Pada era globalisasi, perdagangan internasional memungkinkan orang untuk menghasilkan produk terbaik dan mengonsumsi berbagai macam barang dan jasa yang diproduksi di seluruh dunia. Bagi suatu negara, perdagangan internasional berperan penting untuk meningkatkan standar hidup dan memungkinkan setiap negara untuk mengkhususkan diri dalam memproduksi barang dan jasa yang memiliki keunggulan komparatif.

Salah satu indikator untuk memantau peningkatan perdagangan internasional adalah dengan melihat pertumbuhan ekspor. Ekspor memiliki peranan penting dalam pertumbuhan ekonomi, khususnya pada negara-negara berkembang seperti Indonesia. Meningkatnya kinerja ekspor akan memiliki dampak langsung terhadap peningkatan pertumbuhan ekonomi. Hal ini berarti ekspor memiliki manfaat yang besar bagi perekonomian suatu negara.

Nilai ekspor suatu waktu memiliki kecenderungan tergantung pada waktu sebelumnya. Keadaan ekspor Indonesia pada empat tahun terakhir yaitu pada tahun 2011 sebesar 203 miliar US\$, tahun 2012 sebesar 190 miliar US\$. Selanjutnya pada tahun 2013 sebesar 182 miliar US\$ dan tahun 2014 sebesar 176

miliar US\$. Secara umum, nilai ekspor bulanan pada tahun 2015 lebih rendah dibandingkan dengan nilai ekspor bulanan pada tahun 2014. Meskipun tren ekspor mengalami penurunan pada awal 2015, namun neraca perdagangan Indonesia justru mengalami surplus karena pada saat yang sama nilai impor juga mengalami penurunan. Berdasarkan klasifikasi komoditi, komoditi yang memberikan kontribusi cukup besar terhadap nilai ekspor Indonesia masih berasal dari komoditi ekspor non migas, salah satunya adalah perikanan.

Badan Pusat Statistik (BPS) mencatat pada tahun 2013 nilai ekspor perikanan Indonesia mencapai US\$ 2,86 miliar, kemudian pada tahun 2014 naik menjadi US\$ 3,1 miliar. Lalu pada kuartal I 2015 nilai ekspor perikanan sudah menembus US\$ 906,77 juta. Dari total ekspor kuartal I 2015 tersebut tercatat komoditas yang paling banyak menyumbang nilai ekspor adalah udang beku yakni sebesar US\$ 449,95 juta, terbesar kedua yakni tuna dengan nilai US\$ 89,41 juta dan terbesar ketiga disumbang oleh komoditas cumi-cumi yakni senilai US\$29,51 juta.

Ketersediaan data nilai ekspor maupun impor sangat penting bagi pengambilan keputusan dan kebijakan perdagangan luar negeri yang dilakukan oleh pemerintah Indonesia. Badan Pusat Statistik (BPS) merupakan lembaga negara non kementerian yang bertanggung jawab untuk menyediakan data bagi kebutuhan pemerintah dan masyarakat. Secara berkala, BPS menerbitkan Berita Resmi Statistik (BRS) yang memuat laporan bulanan perkembangan nilai ekspor dan impor. Namun demikian, data perkembangan ekspor yang disajikan dalam BRS merupakan data pada rentang waktu hingga dua bulan sebelum BRS dipublikasikan. Tantangan utama selama dekade mendatang adalah untuk mengembangkan teknologi peramalan efektif atas nilai ekspor.

Pengembangan metode peramalan terhadap data ekspor telah banyak dikembangkan dan masih menjadi isu yang cukup menarik. Di Indonesia, Triyanto (2012) pernah meramalkan data ekspor Indonesia periode Juli 2011-Juni 2012 menggunakan metode hibrida ARIMA-NN. Sebelumnya, Wienarti (2011) juga meramalkan nilai ekspor Jawa Tengah dengan metode *exponential smoothing*. Barus (2013) dan Ruslan, Harahap, Sembiring (2013) juga melakukan peramalan pada data ekspor Sumatera Utara periode November 2012-Oktober

2014. Sedangkan di luar negeri, peramalan data ekspor juga telah banyak dikembangkan, diantaranya oleh Thomson (1994) di New Zealand, Kargbo (2007) di Afrika Selatan, Stoevsky (2009) di Bulgaria, Mehmood (2012) di Pakistan, Arumugam dan Anithakumari (2013) di Taiwan, Zhang dan Zhao (2013) di Ningbo, Tahir (2014) di Pakistan, juga Sen, Sabur, Islam, dan Alam (2015) di Bangladesh.

Pada awalnya metode peramalan (*forecasting*) didominasi oleh metode linier (Zhang, 2004). Metode linier relatif mudah dikembangkan dan diimplementasikan. Namun demikian, metode linier tidak dapat menangkap hubungan non linier yang banyak dijumpai pada kondisi riil. Secara umum pemodelan pada analisis deret waktu terbagi atas dua klasifikasi, *univariate* dan *multivariate*. Model *univariate* yang sering digunakan untuk menganalisis data-data ekonomi antara lain metode *exponential smoothing*, ARIMA, dan ARCH/GARCH. Sedangkan model *multivariate* yang sering digunakan adalah Vektor Auto Regressive (VAR). Analisis deret waktu *univariate* cocok digunakan untuk memodelkan data-data yang sulit diketahui secara pasti penyebab fluktuasinya seperti data-data pada makro ekonomi, yang dalam hal ini adalah data ekspor. Analisis ini memiliki kelebihan yaitu dapat menggunakan data variabel yang akan dilihat perilakunya saja, tanpa perlu mencari data variabel lain yang mempengaruhinya (Makridakis dkk., 1999).

Yule (1927) memperkenalkan model auto regresi (AR) untuk meramalkan bilangan tahunan sunspot dan mengawali perkembangan pemodelan statistik untuk analisis deret waktu. Sampai tahun 1980-an, sebagian besar peneliti memfokuskan penelitiannya pada model deret waktu linier, khususnya kelas model linier *Autoregressive Integrated Moving Average* (ARIMA). Prosedur yang lengkap untuk metodologi model ARIMA yang sampai sekarang digunakan sebagai prosedur standar dalam pembentukan model deret waktu linier dikembangkan oleh Box dan Jenkins (1976), Cryer (1986), Wei (1990), dan Box dkk. (1994) juga banyak membahas model ARIMA dalam literturnya.

Beberapa tahun terakhir, banyak fenomena yang muncul dan terjadi seringkali merupakan fenomena yang nonlinier, yang artinya hubungan antara kejadian di masa lalu dan sekarang bersifat non-linier. Akibatnya, kelompok

pemodelan deret waktu yang linier tidaklah cukup dan sesuai untuk kasus-kasus tersebut. Hal ini ditambah lagi dengan fenomena data yang tidak memenuhi asumsi-asumsi yang disyaratkan untuk analisis deret waktu secara linier. Akibatnya, model-model deret waktu nonlinier telah menjadi fokus perhatian utama peneliti deret waktu pada beberapa tahun terakhir ini. Beberapa bentuk model nonlinier telah dikembangkan dan diaplikasikan pada beberapa kasus deret waktu, dan sudah dipublikasikan pada Tong (1983), Priestley (1988), Lee dkk. (1993), serta Granger dan Terasvirta (1993).

Artificial Neural Network atau biasa disebut *Neural Network* merupakan metode yang saat ini mengalami kemajuan pesat. Analisis deret waktu nonlinier menjelaskan hubungan nonlinier antar variabel dan beberapa prosedur pengujian untuk mendeteksi keterkaitan nonlinier dapat dilihat pada tulisan Granger dan Terasvirta (1993). NN telah terbukti kehandalannya dalam menangani berbagai masalah pada berbagai disiplin keilmuan. Kehandalan tersebut salah satunya disebabkan oleh kemampuan yang dimiliki oleh NN yang sering disebut sebagai *universal approximation*, yaitu dapat mengaproksimasi semua fungsi kontinu multivariat untuk semua tingkat akurasi termasuk untuk fungsi-fungsi non linier. Dengan kemampuan tersebut, NN sering dianggap sebagai pendekatan universal terhadap data tanpa membutuhkan asumsi-asumsi statistik (Hornik, Stinchcombe, dan White, 1989). Kemampuan NN ini digunakan oleh sejumlah peneliti untuk peramalan data deret waktu pada berbagai jenis data, antara lain Suryono (2009), Nuraeni (2009), Susanto (2009), Rokimah (2012), Triyanto (2012). Dari sejumlah penelitian tersebut, NN menunjukkan kinerja yang memuaskan dalam peramalan data deret waktu. Mekanisme kerja NN meniru cara kerja jaringan saraf biologis. Seperti jaringan saraf biologis, NN tersusun atas sel-sel saraf (*neuron*) yang saling terhubung dan beroperasi secara paralel.

Model *Feed Forward Neural Network* (FFNN) adalah salah satu bentuk model NN yang dianggap sangat fleksibel yang dapat digunakan dalam berbagai aplikasi. Dalam mendapatkan model FFNN yang sesuai (arsitektur optimal) perlu ditentukan kombinasi yang tepat antara banyaknya variabel input dan banyaknya unit pada *hidden layer*. Kaashoek dan Van Dijk (2002) memperkenalkan suatu prosedur "*pruning*" untuk mendapatkan arsitektur NN yang optimal. Hasil-hasil

dari kajian pada prosedur pembentukan model FFNN untuk peramalan deret waktu juga telah dipublikasikan oleh Tang dan Fishwick (1993), Kuan, dan Liu (1995), Law (1999), Coulibaly, Anciau, dan Bobee (2000), Shamseldin, Nasr, dan O'Connor (2002), Mishra dan Desai (2006), Suhartono (2007), serta Gaxiola, Melin, Valdez, dan Castillo (2014, 2015).

Model ARIMA dan NN merupakan model yang sering digunakan dalam pemodelan linier maupun nonlinier. Tetapi kedua model tersebut bukanlah model yang universal. Model yang universal adalah model yang dapat dipakai dalam semua kondisi. Pendekatan model ARIMA mungkin kurang tepat untuk permasalahan nonlinier yang kompleks, sedangkan menggunakan NN untuk permasalahan model linier juga kurang tepat. Karena itu kurang bijaksana jika menggunakan NN secara sembarangan. Dalam permasalahan sehari-hari sulit untuk mengetahui karakteristik data sehingga penggabungan kedua metode merupakan strategi yang tepat.

Akurasi seperti prediksi *real time* selalu menjadi tugas yang menantang. Pemilihan metode peramalan yang efisien merupakan faktor yang sangat penting dalam domain masalah tersebut. Di masa lalu, metode statistik klasik digunakan untuk peramalan deret waktu tetapi saat ini data deret waktu dari sistem yang kompleks seperti nilai ekspor telah dikomposisi menjadi model matematika deterministik maupun oleh model probabilistik. Dalam skenario ini, teknik komputasi lunak seperti penalaran probabilistik, logika *fuzzy*, genetika algoritma, NN, dll digunakan sebagai alternatif untuk metode deret waktu klasik. Desain yang efektif dan model peramalan yang konsisten diperlukan untuk mencapai prediksi yang akurat. Karena ketidakpastian dan beberapa parameter yang tidak diketahui pada nilai ekspor, model peramalan deret waktu *fuzzy* menjadi pilihan pertama untuk tujuan peramalan. Metode yang diusulkan memberikan dasar yang kuat untuk pengembangan dan penerapan metode deret waktu *fuzzy* untuk peramalan nilai ekspor dalam jangka pendek.

Weighted Fuzzy Time series (WFTS) diusulkan pertama kali oleh Yu (2005). Model ini memberikan lebih banyak bobot terhadap aturan *fuzzy* terkini dibandingkan bobot pada aturan *fuzzy* terdahulu. Model WFTS hampir menyerupai fungsi bobot pada model regresi lokal, namun demikian, keduanya

berbeda. Model regresi lokal berfokus pada pemodelan menggunakan sebagian kecil dari data, sedangkan hubungan *fuzzy* pada model WFTS dibangun menggunakan data yang memungkinkan dari keseluruhan basis data. Sejumlah penelitian telah dikembangkan menggunakan metode WFTS, diantaranya Chang (2007), Sang-Hong (2010), Cheng (2007), Cheng (2011), Yungho (2011), dan Lee (2012). Sedangkan di Indonesia, penelitian serupa juga telah dilakukan oleh Putro (2015), dan Lusia (2013).

Beranjak dari uraian diatas, penelitian ini akan menggunakan metode ARIMA, FFNN, Hibrida ARIMA– NN, serta WFTS untuk mendapatkan model peramalan terbaik pada data volume ekspor perikanan Indonesia. Metode ARIMA digunakan untuk mendapatkan arsitektur NN yang paling sesuai sehingga dapat diperoleh model NN dengan kinerja peramalan terbaik. Arsitektur yang dimaksud adalah banyaknya input serta jumlah *neuron* pada lapisan tersembunyi yang akan digunakan dalam pemodelan NN, sedangkan algoritma yang digunakan pada penelitian ini adalah algoritma *back-propagation*.

1.2 Perumusan Masalah

Berdasarkan latar belakang masalah diatas, penelitian ini dilakukan untuk meramalkan volume ekspor perikanan, yang dirumuskan sebagai berikut:

1. Bagaimana model peramalan volume ekspor perikanan Indonesia dengan menggunakan ARIMA?
2. Bagaimana model peramalan volume ekspor perikanan Indonesia dengan menggunakan *Feed Forward Neural Network*?
3. Bagaimana model peramalan volume ekspor perikanan Indonesia dengan menggunakan *Weighted Fuzzy Time series* ?
4. Bagaimana mengetahui tingkat kehandalan hasil prediksi dari masing-masing model tersebut?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah diuraikan diatas, maka tujuan yang ingin dicapai dalam penelitian ini adalah:

1. Mendapatkan model ARIMA yang sesuai untuk peramalan volume ekspor perikanan Indonesia
2. Mendapatkan arsitektur FFNN terbaik yaitu kombinasi input dan jumlah *hidden neuron* yang sesuai untuk peramalan data volume ekspor perikanan Indonesia
3. Mendapatkan model *Weighted Fuzzy Time series* yang sesuai untuk peramalan volume ekspor perikanan Indonesia
4. Melakukan perbandingan metode peramalan konvensional yakni ARIMA dengan metode peramalan modern yakni *Feed Forward Neural Network* dan *Weighted Fuzzy Time series*.

1.4 Manfaat Penelitian

Secara umum, penelitian ini diharapkan dapat dimanfaatkan oleh Pemerintah, BPS, dan para pengguna data lainnya. Secara khusus, manfaat yang diharapkan tersebut dirinci sebagai berikut:


1. Tersedianya data ramalan volume ekspor perikanan Indonesia untuk melengkapi ketersediaan data di Badan Pusat Statistik (BPS).
2. Tersedianya informasi bagi pemerintah sebagai dasar pengambilan kebijakan yang relevan bagi perdagangan luar negeri, khususnya sektor perikanan serta strategi meningkatkan kinerja ekspor perikanan Indonesia.
3. Tersedianya informasi bagi negara-negara lain yang memainkan peran dalam perdagangan luar negeri dan menguasai pangsa pasar kawasan mengenai kekuatan ekspor perikanan Indonesia.

1.5 Batasan Permasalahan

Terdapat sejumlah metode peramalan, baik konvensional maupun modern, untuk diaplikasikan pada peramalan data ekspor. Penelitian ini menitikberatkan dan membatasi permasalahan sebagai berikut:

1. Melakukan kajian peramalan univariat dengan metode peramalan klasik, yakni ARIMA, serta metode modern, yakni *Feed Forward Neural Network* dan *Weighted Fuzzy Time series* untuk data ekspor perikanan Indonesia tanpa mempertimbangkan pengaruh dari variabel lainnya.

2. Menggunakan data volume ekspor perikanan Indonesia pada periode bulan Januari 1999 sampai dengan bulan Juli 2015.



BAB 2

TINJAUAN PUSTAKA

Pada bab ini akan diuraikan sejumlah teori yang dijadikan sebagai landasan bagi penelitian dan berasal dari sejumlah literatur terkait. Adapun literatur yang digunakan diantaranya bersumber dari jurnal, tesis, disertasi, buku, dan literatur lain yang telah dipublikasikan. Pokok bahasan dalam bab ini mencakup perdagangan internasional yang dibatasi pada kegiatan ekspor, model peramalan klasik, serta model peramalan modern.

2.1 Perdagangan Internasional

Perdagangan internasional merupakan hubungan kegiatan ekonomi antarnegara yang diwujudkan dengan adanya proses pertukaran barang atau jasa atas dasar suka rela dan saling menguntungkan. Di banyak negara, perdagangan internasional menjadi salah satu faktor utama untuk meningkatkan GDP. Meskipun perdagangan internasional telah terjadi selama ribuan tahun, tetapi dampaknya terhadap kepentingan ekonomi, sosial, dan politik, baru dirasakan beberapa abad belakangan. Perdagangan internasional juga turut mendorong industrialisasi, kemajuan transportasi, globalisasi, dan kehadiran perusahaan multinasional.

Menurut Sukirno (2006), manfaat perdagangan internasional lainnya adalah sebagai berikut:

a. Efisiensi

Melalui perdagangan internasional, setiap negara tidak perlu memproduksi semua kebutuhannya, tetapi cukup hanya memproduksi apa yang bisa diproduksinya dengan cara yang paling efisien dibandingkan dengan negara-negara lain. Dengan demikian, akan tercipta efisiensi dalam pengalokasian sumber daya ekonomi dunia.

b. Perluasan konsumsi dan produksi

Perdagangan internasional juga memungkinkan konsumsi yang lebih luas bagi penduduk suatu negara.

c. Peningkatan produktivitas

Negara-negara yang berspesialisasi dalam memproduksi barang tertentu akan berusaha meningkatkan produktivitasnya. Dengan demikian mereka akan tetap unggul dari negara lain dalam memproduksi barang tersebut.

d. Sumber penerimaan negara

Perdagangan internasional bisa menjadi sumber pemasukan kas negara dari pajak-pajak ekspor dan impor.

2.2 Perkembangan Ekspor Indonesia

Seiring dengan perkembangan globalisasi, kegiatan ekspor maupun impor menjadi semakin penting karena merupakan salah satu penggerak perekonomian bagi suatu negara. Era globalisasi dan perdagangan bebas telah mendorong persaingan antar negara menjadi semakin ketat. Setiap negara, termasuk Indonesia, berusaha terus meningkatkan kuantitas dan juga kualitas ekspornya. Indonesia dan negara-negara lainnya terus meningkatkan daya saing produknya agar lebih efisien dan laku di pasar internasional. Dilihat dari perkembangan ekspor Indonesia, produk ekspor Indonesia didominasi oleh ekspor nonmigas.

Selama periode 2007 sampai 2013 rata-rata peranan ekspor nonmigas Indonesia mencapai 81,08 persen, sedangkan rata-rata peranan ekspor migas hanya mencapai 18,92 persen. Ekspor migas dari tahun ke tahun memang menunjukkan kecenderungan penurunan. Hal ini memberikan isyarat kepada pemerintah Indonesia untuk mengambil langkah kebijakan meningkatkan ekspor nonmigas. Informasi mengenai perkembangan ekspor Indonesia menurut komoditi sangat diperlukan oleh pemerintah dalam menentukan kebijakan dalam bidang perdagangan, baik nasional maupun internasional. Pengetahuan tersebut juga penting bagi dunia usaha dalam menentukan strategi usahanya.

Selama periode 2007 sampai 2013, pada tahun 2012 dan 2013 neraca perdagangan Indonesia berturut-turut mengalami defisit. Defisit neraca perdagangan Indonesia tahun 2012 sebesar US\$ 1.669,2 juta selanjutnya pada tahun 2013 sebesar US\$ 4.076,8 juta. Defisit neraca perdagangan Indonesia tahun 2013 semakin besar karena penurunan nilai ekspor pada tahun 2013 lebih besar jika

dibandingkan penurunan nilai impor. Pada tahun 2013 nilai ekspor mengalami penurunan sebesar 3,93 persen sedangkan nilai impor mengalami penurunan sebesar 2,64 persen.

Menurunnya nilai ekspor Indonesia pada tahun 2013 bisa diindikasikan karena menurunnya harga beberapa komoditas ekspor Indonesia di pasar internasional. Hal ini dapat dilihat dari meningkatnya volume ekspor Indonesia sebesar 16,64 persen di saat nilai ekspor Indonesia mengalami penurunan sebesar 3,93 persen. Beberapa komoditi yang mengalami penurunan harga ekspor di pasar internasional diantaranya adalah karet alam, biji coklat, kopi, nikel dan tembaga.

2.3 Peramalan

Dalam empat dekade terakhir ini telah terjadi perkembangan dalam bidang pendugaan (*prediction*) dan penaksiran (*estimation*) yang memiliki kaitan dan dapat digunakan secara langsung dalam peramalan. Peramalan merupakan proses yang dilakukan ketika ada kesenjangan waktu (*lag*) dari data aktual pada waktu tertentu dengan data yang ingin diketahui di masa yang akan datang. Peramalan diperlukan untuk mengetahui kapan suatu peristiwa akan terjadi, sehingga tindakan yang tepat dapat dilakukan (Makridakis, Wheelwright, dan Hyndman, 1998).

Kecenderungan untuk dapat meramalkan peristiwa secara lebih tepat akan terus menerus memberikan dasar yang lebih baik bagi perencanaan. Dengan adanya sejumlah besar metode peramalan yang tersedia, maka masalah yang timbul bagi para praktisi adalah memahami bagaimana karakteristik suatu metode peramalan akan cocok bagi situasi pengambilan keputusan tertentu. Situasi peramalan sangat beragam dalam horison waktu peramalan, faktor yang menentukan hasil sebenarnya, tipe pola data dan berbagai aspek lainnya. Untuk itu, sejumlah teknik telah dikembangkan dan dikelompokkan menjadi dua kategori utama, yakni metode kuantitatif dan metode kualitatif.

Metode kuantitatif meliputi deret waktu (*time series*) dan metode kausal. Sedangkan metode kualitatif meliputi metode eksplorasi dan normatif. Pada model deret waktu, pendugaan masa depan dilakukan berdasarkan nilai masa lalu dari suatu variabel dan/atau kesalahan masa lalu. Tujuan dari metode ini adalah

menemukan pola dalam deret historis dan mengekstrapolasikan pola tersebut ke masa depan.

2.4 Analisis Deret Waktu

Setiap nilai dari hasil pengamatan (data) pada dasarnya selalu memiliki keterkaitan dengan waktu pengamatannya. Namun demikian, dalam melakukan analisis, seringkali variabel waktu dengan pengamatan tidak dikaitkan. Data deret waktu merupakan serangkaian data yang berupa nilai pengamatan yang diukur selama kurun waktu tertentu, berdasarkan interval waktu yang tetap (Wei, 2006). Sifat alami dari data deret waktu adalah antar pengamatan tidak independen. Pengamatan yang berdekatan saling berhubungan atau berkorelasi, dimana data saat ini dipengaruhi oleh satu atau beberapa data sebelumnya.

Berbeda dengan analisis data lainnya, analisis deret waktu lebih memfokuskan untuk melihat perilaku data, bagaimana data bergerak, tanpa mengkaji faktor-faktor apa yang menyebabkan pergerakan data tersebut. Terdapat dua alasan mengapa analisis deret waktu tidak mengkaji faktor-faktor penyebab pergerakan data. Pertama, faktor-faktor penyebab pergerakan data tidak dimengerti, dan walaupun hal itu diketahui, sangat sulit mengukur hubungan sebab akibatnya. Kedua, perhatian utama peneliti hanya untuk meramalkan apa yang akan terjadi dan bukan mengetahui mengapa hal itu terjadi (Makridakis dkk., 1998).

2.5 Metode ARIMA

Metode ARIMA merupakan kombinasi dari proses *Autoregressive* (AR) dan *Moving Average* (MA) yang digunakan dalam model peramalan pada data deret waktu non stasioner. Model ARIMA merupakan model yang sangat kuat dalam peramalan jangka pendek. Metode ARIMA dibagi kedalam empat kelompok model deret waktu linier, yaitu: model AR, MA dan model campuran yang memiliki karakteristik kedua model di atas yaitu ARMA dan ARIMA.

Secara umum model ARIMA (p,d,q) terdiri dari tiga komponen, yaitu:

- a. Komponen AR(p)
- b. Komponen *differencing*, dimana data deret waktu menjadi stasioner setelah melalui *d differencing*, dan
- c. Komponen MA(q)

Adapun model ARIMA dalam notasi *backshift* berdasarkan literatur Makridakis dkk. (1998) dapat dituliskan secara matematis sebagai berikut:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d Y_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) e_t \quad (2.1)$$

dimana

Y_t = data deret waktu sebagai variabel respon pada waktu ke- t

$\theta_1, \theta_2, \dots, \theta_q$ = parameter-parameter *moving average*

$\phi_1, \phi_2, \dots, \phi_p$ = parameter-parameter *autoregressive*

e_t = nilai kesalahan pada kurun waktu ke- t

Penulisan derajat *difference* (d) menggambarkan suatu proses ARIMA dalam dimensi p, d, q sehingga ARIMA dapat diinterpretasikan sebagai suatu deret waktu yang mengikuti proses AR(p), MA(q), dan menjadi stasioner setelah *difference* ke- d .

Proses transformasi data dapat dilakukan untuk mengatasi masalah data deret waktu tidak stasioner dalam varians. Model transformasi yang sering digunakan adalah transformasi Box-Cox (Wei, 2006):

$$T(Y_t) = Y_t^{(\lambda)} = \frac{Y_t^\lambda - 1}{\lambda} \quad (2.2)$$

dengan λ adalah parameter transformasi. Jika $\lambda = 0$, maka dapat dilakukan pendekatan:

$$\lim_{\lambda \rightarrow 0} T(Y_t) = \lim_{\lambda \rightarrow 0} Y_t^{(\lambda)} = \lim_{\lambda \rightarrow 0} \frac{Y_t^\lambda - 1}{\lambda} \quad (2.3)$$

2.5.1 Model ARIMA musiman

Selain digunakan untuk model non musiman, model ARIMA juga dapat digunakan untuk model musiman. Model *time series* musiman adalah model time series yang mempunyai sifat “berulang setelah sekian periode waktu tertentu,

misalnya satu tahunan untuk *time series* bulanan, ataupun satu mingguan untuk *time series* harian. Model ARIMA musiman dinyatakan dalam

$$\Phi_p(B^s)(1 - B^s)^D \dot{Y}_t = \Theta_Q(B^s)e_t \quad (2.4)$$

Sedangkan gabungan antara model ARIMA non musiman dan ARIMA musiman disebut ARIMA multiplikatif yang dinyatakan sebagai berikut:

$$\Phi_p(B^s)\phi_p(B)(1 - B)^d(1 - B^s)^D \dot{Y}_t = \theta_q(B)\Theta_Q(B^s)e_t \quad (2.5)$$

dimana:

$\Phi_p(B^s)$ = koefisien komponen AR musiman s dengan orde P

$\Theta_Q(B^s)$ = koefisien komponen MA musiman s dengan orde Q

$(1 - B^s)^D$ = perbedaan (*differencing*) musiman pada orde ke-D

2.5.2 *Outlier time series*

Pengamatan data deret waktu seringkali dipengaruhi oleh kejadian-kejadian yang tidak biasa seperti krisis ekonomi, bencana alam, ataupun kesalahan pencatatan dan perekaman sehingga dapat merusak analisis data dan membuat hasil kesimpulan yang keliru atau tidak valid. Pengamatan yang tidak biasa ini disebut *outlier*. Keberadaan *outlier* pada suatu data deret waktu dapat berdampak secara substansial pada bentuk ACF sampel, PACF, estimasi parameter model ARMA, peramalan dan juga terhadap spesifikasi model. Oleh karena itu penting untuk memiliki suatu prosedur untuk mendeteksi dan menghilangkan efek dari *outlier*.

Misalkan Y_t sebagai deret waktu yang diamati dan X_t adalah series *outlier*.

Asumsikan $\{X_t\}$ mengikuti suatu model ARMA (p,q)

$$\phi(B)X_t = \theta(B)e_t \quad (2.6)$$

dimana $\phi_p(B) = 1 - \phi_1B - \dots - \phi_pB^p$ dan $\theta_q(B) = 1 - \theta_1B - \dots - \theta_qB^q$

adalah stasioner dan *invertible* dan $\{e_t\}$ adalah deret residual yang *white noise*, *i. i. d.* $\sim N(0, \sigma_e^2)$. Model *Additive outlier* (AO) didefinisikan sebagai berikut:

$$Y_t = \begin{cases} X_t, & t \neq T \\ X_t + \omega, & t = T \end{cases} \quad (2.7)$$

$$= X_t + \omega I_t^{(T)} \quad (2.8)$$

$$= \frac{\theta(B)}{\phi(B)} e_t + \omega I_t^{(T)} \quad (2.9)$$

dimana $I_t^{(T)} = \begin{cases} 0, & t \neq T \\ 1, & t = T \end{cases}$ adalah variabel indikator yang mewakili ada atau tidaknya sebuah *outlier* pada waktu T. ω menyatakan besarnya pengaruh *outlier* dan sebagai model dinamik dari efek *outlier*. AO merupakan kejadian yang mempengaruhi suatu deret waktu pada suatu titik waktu saja.

Model *Innovative outlier* (IO) didefinisikan sebagai berikut:

$$Y_t = X_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)} \quad (2.10)$$

$$= \frac{\theta(B)}{\phi(B)} (e_t + \omega I_t^{(T)}) \quad (2.11)$$

Additive outlier hanya mempengaruhi pengamatan Y_t pada waktu ke- t dan *Innovative outlier* mempengaruhi seluruh pengamatan Y_t, Y_{t+1}, \dots melewati waktu t sepanjang memori dari sistem yang diberikan oleh $\frac{\theta(B)}{\phi(B)}$.

Secara umum, suatu data time series mungkin mengandung beberapa *outlier*, misalkan k *outlier* yang berbeda jenis, maka model *outlier* secara umum dapat dinyatakan sebagai berikut:

$$Y_t = \sum_{j=1}^k \omega_j v_j(B) I_t^{(T)} + X_t \quad (2.12)$$

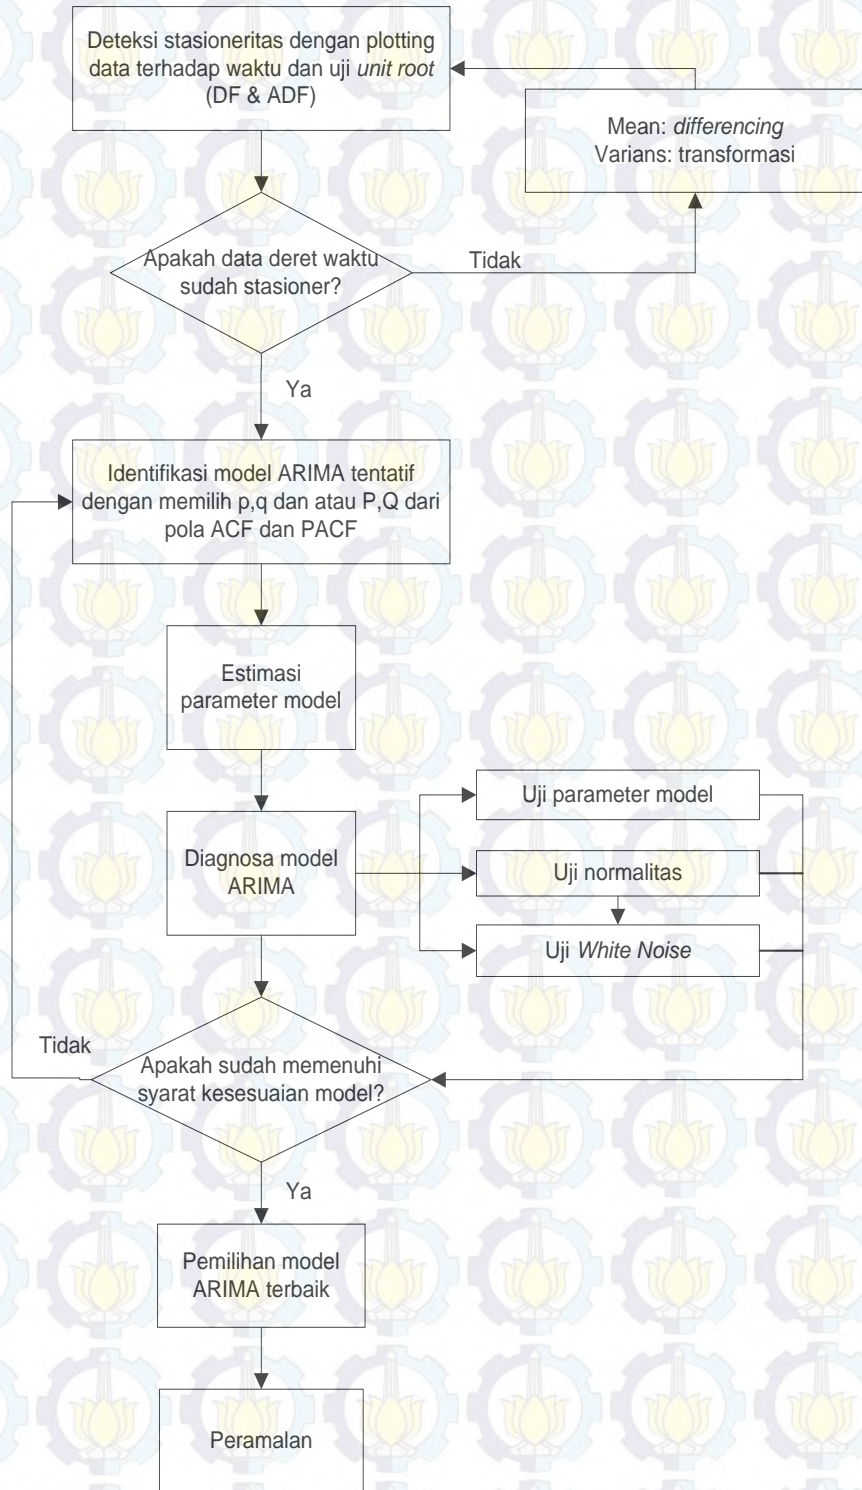
Kadangkala, waktu dan penyebab terjadinya *outlier* tidak diketahui sehingga AO dan IO dapat bersifat *level shift* (LS) dan *temporary change* (TC). LS merupakan kejadian yang mempengaruhi deret pada suatu waktu tertentu dan efek yang diberikan memberikan suatu perubahan yang tiba-tiba dan bersifat tetap. LS didefinisikan sebagai berikut:

$$LS: Y_t = X_t + \frac{1}{(1-B)} \omega_L I_t^{(T)} \quad (2.13)$$

Sedangkan TC adalah suatu kejadian dimana *outlier* menghasilkan efek awal pada waktu t , dan kemudian efek tersebut berkurang secara lambat laun seiring dengan berkurangnya nilai faktor (δ). TC didefinisikan sebagai berikut:

$$TC: Y_t = X_t + \frac{1}{(1-\delta B)} \omega_C I_t^{(T)} \quad (2.14)$$

Secara lengkap prosedur untuk memperoleh model ARIMA terbaik dapat dilihat pada bagan dibawah ini:



Gambar 2.1 Tahapan ARIMA

2.5.3 Stasioneritas Data

Data stasioner adalah data yang tidak mengalami pertumbuhan atau perubahan. Secara kasar, data stasioner mempunyai pola horizontal sepanjang sumbu waktu. Dengan kata lain, fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan fluktuasi dari varians tersebut, sehingga pada dasarnya tetap konstan setiap waktu. Jika data deret waktu tidak stasioner pada rata-ratanya, untuk menstasionerkan, maka dapat dilakukan proses *differencing*. Sedangkan jika data deret waktu tidak stasioner pada varians, dapat dilakukan transformasi Box-Cox (Wei, 2006).

2.5.4 Identifikasi Model

Tahap identifikasi merupakan tahap untuk menentukan orde p, d, q sementara (*tentative*) yang sesuai. Jika data tidak mengalami *differencing*, maka d bernilai 0. Jika data stasioner setelah *differencing* pertama, maka d bernilai 1, dan seterusnya. Sedangkan dalam menentukan orde p dan q dapat dibantu dengan mengamati pola ACF dan PACF sebagai berikut (Bowerman & O'Connell, 1987):

Tabel 2.1 Karakteristik ACF dan PACF untuk penentuan model ARIMA

No	Model	ACF	PACF
Non Musiman			
1	$AR(p)$	Turun cepat	Terpotong setelah lag p
2	$MA(q)$	Terpotong setelah lag q	Turun cepat
3	$ARMA(p, q)$	Turun cepat	Turun cepat
4	$AR(p)$ atau $MA(q)$	Terpotong setelah lag q	Terpotong setelah lag p
Musiman			
1	$MA(Q)^S$	Terpotong setelah lag QS	Turun cepat di lag musiman ($S, 2S, 3S, \dots$)
2	$AR(P)^S$	Turun cepat di lag musiman ($S, 2S, 3S, \dots$)	Terpotong setelah lag PS
3	$ARMA(P, Q)^S$	Turun cepat di lag musiman ($S, 2S, 3S, \dots$)	Turun cepat di lag musiman ($S, 2S, 3S, \dots$)
4	$AR(P)^S$ atau $MA(Q)^S$	Terpotong setelah lag QS	Terpotong setelah lag PS
	<i>White noise</i> atau <i>random process</i>	Tidak ada ACF yang signifikan	Tidak ada PACF yang signifikan

2.5.5 Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

Salah satu identifikasi stasioneritas $\{Z_t\}$ yang sederhana adalah berdasarkan (ACF) atau korelasi antara Z_t dan Z_{t+k} . ACF pada lag ke- k didefinisikan sebagai berikut (Wei, 2006):

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, \quad k = 0, 1, 2, \dots \quad (2.15)$$

PACF digunakan sebagai alat untuk mengukur tingkat keeratan antara Z_t dan Z_{t+k} setelah mengeliminir dependensi $Z_{t+1}, \dots, Z_{t+k-1}$. PACF dinotasikan dengan ϕ_{kk} dengan penghitungan sebagai berikut:

$$\phi_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.16)$$

dan

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}, \quad j = 1, \dots, k \quad (2.17)$$

2.5.6 Estimasi dan Uji Signifikansi Parameter

Menurut Wei (2006) terdapat sejumlah metode untuk mengestimasi nilai parameter pada ARIMA, yakni metode *moment*, *maximum likelihood*, nonlinier, dan *ordinary least squares* (OLS). Bagian ini akan menguraikan estimasi parameter dengan metode *Maximum Likelihood Estimation* (MLE) berdasarkan literatur Wei (2006).

Dari persamaan (2.1) dapat diperoleh bentuk umum ARMA atau ARIMA (p,0,q) yang ditulis secara matematis sebagai berikut:

$$(1 - \phi_1 B - \dots - \phi_p B^p) Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) e_t \quad (2.18)$$

dimana e_t merupakan *white noise* berdistribusi $N(0, \sigma_e^2)$. Box, Jenkins, dan Reinsel (1994) menggunakan fungsi *unconditional log-likelihood* sebagai berikut:

$$\ln L(\phi, \mu, \theta, \sigma_e^2) = -\frac{n}{2} \ln 2\pi\sigma_e^2 - \frac{S(\phi, \mu, \theta)}{2\sigma_e^2} \quad (2.19)$$

dimana $S(\phi, \mu, \theta)$ merupakan fungsi *unconditional sum of squares* yaitu:

$$S(\phi, \mu, \theta) = \sum_{t=-\infty}^n [E\langle e_t | \phi, \mu, \theta, Z \rangle]^2 \quad (2.20)$$

dan $E\langle e_t | \phi, \mu, \theta, Z \rangle$ merupakan ekspektasi bersyarat dari e_t dengan syarat ϕ, μ, θ, Z . Nilai dari $\hat{\phi}$, $\hat{\mu}$, dan $\hat{\theta}$ yang memaksimumkan fungsi pada persamaan (2.8) disebut sebagai penduga *unconditional maximum likelihood*. Karena $\ln L(\phi, \mu, \theta, e_t^2)$ hanya terdiri dari data hingga $S(\phi, \mu, \theta)$, maka penduga *unconditional maximum likelihood* adalah sama dengan penduga *unconditional least square* yang diperoleh dengan meminimumkan $\ln L(\phi, \mu, \theta, e_t^2)$. Dalam prakteknya, penjumlahan dari persamaan (2.9) dapat diperoleh melalui pendekatan dari:

$$S(\phi, \mu, \theta) = \sum_{t=-M}^n [E\langle e_t | \phi, \mu, \theta, Z \rangle]^2 \quad (2.21)$$

dimana M merupakan suatu angka berukuran besar yang dapat menghasilkan nilai $||[E\langle Z_t | \phi, \mu, \theta, Z \rangle] - [E\langle Z_{t-1} | \phi, \mu, \theta, Z \rangle]||$ lebih kecil dari nilai ε untuk $t \leq -(M + 1)$. Kondisi ini menyiratkan bahwa $E\langle Z_t | \phi, \mu, \theta, Z \rangle \simeq \mu$, sehingga $E\langle Z_t | \phi, \mu, \theta, Z \rangle$ dapat diabaikan untuk $t \leq -(M + 1)$.

Setelah diperoleh estimasi terhadap parameter ϕ, μ , dan θ yaitu $\hat{\phi}, \hat{\mu}$, dan $\hat{\theta}$, proses selanjutnya adalah melakukan estimasi terhadap e_t^2 yaitu \hat{e}_t^2 yang dapat diperoleh melalui persamaan matematis sebagai berikut:

$$e_t^2 = \frac{S(\hat{\phi}, \hat{\mu}, \hat{\theta})}{n} \quad (2.22)$$

2.5.7 Cek Diagnosa

Salah satu tahapan penting dalam membangun model deret waktu adalah diagnosa residual dari model, yaitu residual bersifat *white noise* (tidak ada korelasi serial atau residualnya independen) dan identik (homoskedastis). Selain *white noise*, juga berdistribusi normal.

Pengujian asumsi *white noise* menggunakan uji Ljung-Box dengan hipotesis sebagai berikut:

$H_0: \rho_i = 0, \forall_i$ (residual *white noise*)

$H_1: \rho_i \neq 0, \exists_i \quad i = 1, 2, \dots, K$ (residual tidak *white noise*)

Statistik uji yang digunakan sebagai berikut:

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.23)$$

Dimana

$\hat{\rho}_k$ = ACF residual

n = banyaknya residual

k = lag ke- k

Daerah penolakan: Tolak H_0 jika $Q > \chi_{(\alpha, K-m)}^2$, dengan $m=p+q$ (orde ARMA) atau dengan menggunakan p-value $< \alpha$ artinya model tidak sesuai karena residual tidak memenuhi asumsi *white noise*.

Pengujian selanjutnya yaitu uji asumsi residual berdistribusi normal. Pengujian ini dilakukan dengan menggunakan Kolmogorov-Smirnov. Hipotesis yang digunakan adalah:

$H_0: F_n(e_t) = F_0(e_t)$ atau residual berdistribusi normal

$H_1: F_n(e_t) \neq F_0(e_t)$ atau residual tidak berdistribusi normal

Statistik uji:

$$D_{hitung} = \sup_x |S(e_t) - F_0(e_t)| \quad (2.24)$$

dimana:

$F_0(e_t)$ = fungsi yang dihipotesiskan berdistribusi normal

$F_n(e_t)$ = fungsi distribusi kumulatif dari data asal

n = banyaknya residual

Nilai D_{hitung} dibandingkan dengan nilai D pada tabel Kolmogorov-Smirnov dengan derajat bebas n . Daerah penolakan: Tolak H_0 jika $D_{hitung} > D_{\alpha,n}$ atau dapat menggunakan p -value. Jika p -value $< \alpha$ berarti H_0 ditolak yang berarti residual tidak berdistribusi normal.

2.5.8 Pemilihan Model ARIMA

Penentuan model terbaik dapat dilakukan dengan menggunakan kriteria pemilihan model yang berdasarkan residual dan kesalahan peramalan (Wei, 2006). Adapun kriteria pemilihan model yang berdasarkan residual pada data *in-sample* adalah:

1. AIC (*Akaike's Information Criterion*)

Diasumsikan bahwa model deret waktu mempunyai M parameter. Nilai AIC didefinisikan sebagai berikut:

$$AIC(M) = n \ln \hat{\sigma}_e^2 + 2M \quad (2.25)$$

dengan

n = banyaknya residual

M = jumlah parameter di dalam model

$\hat{\sigma}_e^2$ = varians dari residual dengan MLE

2. Schwartz's SBC

Schwartz (1978) menggunakan kriteria Bayesian untuk pemilihan model terbaik (*Schwartz's Bayesian Criterion*) dan didefinisikan sebagai berikut:

$$SBC(M) = n \ln \hat{\sigma}_e^2 + M \ln n \quad (2.26)$$

Jika tujuan utama pembentukan model adalah untuk peramalan, maka alternatif kriteria pemilihan model adalah berdasarkan kesalahan peramalan untuk data *out-sample*. Anggap kesalahan peramalan untuk l -langkah ke depan adalah:

$$e_t = Z_{n+l} - \hat{Z}_n(l) \quad (2.27)$$

Dimana n adalah titik awal peramalan, ada 4 (empat) nilai statistik yang biasanya digunakan yaitu:

1) MSE (*Mean Square Error*)

$$MSE = \frac{1}{n} \sum_{l=1}^n e_l^2 \quad (2.28)$$

2) MAPE (*Mean Absolute Percentage Error*)

$$MAPE = \left(\frac{1}{n} \sum_{l=1}^n \left| \frac{e_l}{Z_{n+l}} \right| \right) 100\% \quad (2.29)$$

3) RMSE (*Root Mean Square Error*)

$$RMSE = \sqrt{\frac{1}{n} \sum_{l=1}^n e_l^2} \quad (2.30)$$


2.6 Artificial Neural Networks (ANN)

ANN adalah model komputasi untuk memproses informasi dan mengidentifikasi pola. ANN berawal dari penelitian bagaimana memodelkan sistem neural biologi, khususnya otak manusia. ANN menawarkan pendekatan komputasi yang sedikit berbeda dengan komputasi digital konvensional. Komputer digital bekerja secara sekuensial dan dapat mengerjakan komputasi aritmatika dengan sangat cepat. *Neuron* dalam otak manusia sangat lambat tetapi dapat mengerjakan luar biasa banyaknya, pekerjaan komputasi dalam kegiatan sehari-hari, kemudian perasaan, dan membuat keputusan pada situasi yang sulit atau *fuzzy situation*. Tidak seperti komputer konvensional, otak manusia berisi *neuron* yang luar biasa banyaknya, yang merupakan elemen untuk memproses *biological nervous system* yang bekerja secara paralel. ANN dimodelkan dari *neuron* biologis. Namun ANN lebih simpel karena hanya meniru sedikit saja dari *neuron* biologis.

Beberapa atribut utama dari ANN adalah :

- ❖ ANN dapat belajar dari contoh dan menghasilkan dengan baik data yang belum terlihat.
- ❖ ANN dapat digunakan pada situasi dimana input data belum bersih dari kesalahan, belum komplit atau *fuzzy*.
- ❖ ANN cepat dan akurat untuk digunakan dalam memprediksi (Iranmanesh, 2008).

Secara umum, bentuk arsitektur FFNN adalah sebagai berikut:



Gambar 2.2 Arsitektur FFNN dengan satu *hidden layer*, p unit input, q unit *neuron/node* pada *hidden layer*, dan satu unit *neuron/node* pada *output layer*

Struktur dari *neural network* secara umum di jelaskan sebagai berikut:

1) *Neuron*

Neuron adalah dasar dari model *neural network*. *Neuron* adalah saluran komunikasi yang dapat menerima input dan menghasilkan output. *Neuron* dapat menerima input yang berasal dari *neuron* lain atau pun dari user. Begitu juga dengan output, *neuron* dapat menghasilkan output kepada *neuron* lain atau pun ke user.

2) *Neuron connection weight*

Pada dasarnya *Neuron* selalu terhubung bersama. Namun nilai hubungan/sambungan ini tidak selalu sama, dan pada hubungan/sambungan dapat diberikan nilai *weight* individu. *Weight* inilah yang memberikan kemampuan *neural network* untuk dapat mengenali pola tertentu. Dengan menyesuaikan *weight*-nya maka *neural network* akan mengenali pola yang berbeda.

3) *Neuron Layers*

Layer adalah kumpulan dari *neuron* yang melakukan fungsi yang sama. Terdapat tiga jenis *layer* :

- i. *Layer* input adalah *layer* dari *neuron* yang menerima input dari user.

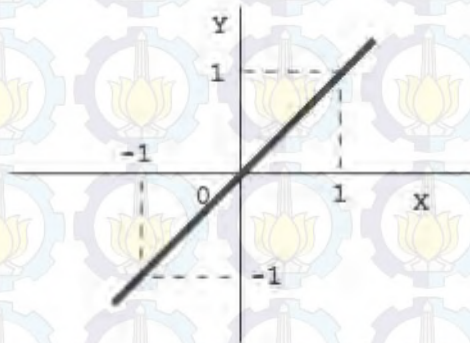
- ii. *Layer hidden* adalah *layer* dari *neuron* yang hanya terhubung ke *neuron* lainnya, dan tidak pernah terhubung langsung dengan *user*.
- iii. *Layer output* adalah *layer* dari *neuron* yang mengirimkan output kepada *user*.

4) Fungsi Aktivasi

Neural network ini diaktifkan dengan suatu fungsi khusus (fungsi aktivasi) dimana fungsi ini menghubungkan *input* yang ada dan memprosesnya hingga menjadi suatu *output* yang diinginkan. Fungsi aktivasi ini mencerminkan kerja sinapsis dalam sistem saraf manusia. Berikut ini 4 macam fungsi aktivasi *neural network*:

(i) Fungsi Linier

Fungsi linier ini dinyatakan dengan $y = f(x)$. Dari fungsi ini, ada kemungkinan dimana nilai *output* sama dengan nilai *input*-nya.



Gambar 2.2 Grafik Fungsi Linier


Fungsi linier ini juga dapat dirumuskan dengan $y = \alpha x$ dimana α adalah kemiringan garis (*slope*).

(ii) Fungsi *Threshold*

Fungsi *threshold* atau fungsi tangga biner atau fungsi *step* merupakan fungsi aktivasi yang digunakan untuk konversi *input* dengan variabel kontinu menjadi *output* yang bernilai biner (0 atau 1). Fungsi ini dapat dituliskan menjadi:

$$y = \begin{cases} 0 & \text{jika } x \leq 0 \\ 1 & \text{jika } x \geq 0 \end{cases}$$

Dengan grafik sebagai berikut.



Gambar 2.3 Grafik Fungsi Treshold

(iii) Fungsi *Sigmoid*


Fungsi ini merupakan fungsi non-linier yang paling banyak digunakan untuk aktivasi *neural network*. Fungsi ini ada dua macam, yaitu fungsi *sigmoid* biner dan fungsi *sigmoid bipolar*. Untuk fungsi *sigmoid biner*, persamaan fungsinya adalah:

$$y = f(x) = \frac{1}{1 + e^{-x}} \quad (2.31)$$

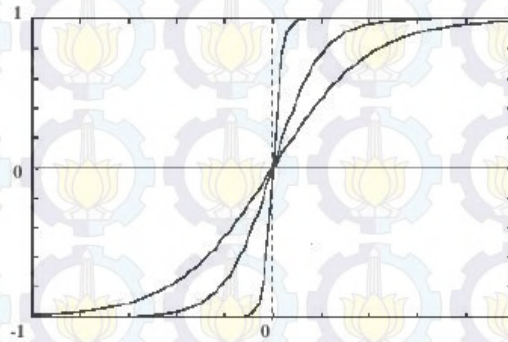
Sedangkan untuk fungsi *sigmoid bipolar* persamaan fungsinya adalah:

$$y = f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.32)$$

Grafik yang dibentuk dari persamaan tersebut sebagai berikut.



Gambar 2.4. Grafik *Sigmoid Biner*



Gambar 2.5 Grafik *Sigmoid Bipolar*

(iv) Fungsi Hiperbolik Tangen

Fungsi aktivasi hiperbolik tangen digunakan untuk mendapatkan *output* antara -1 hingga 1, dimana persamaan fungsinya adalah:

$$y = f(x) = \frac{e^{-x} - e^x}{e^{-x} + e^x} \quad (2.33)$$

$$y = f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (2.34)$$

$$f'(x) = [1 + f(x)][1 - f(x)] \quad (2.35)$$

5) Arsitektur *Neural Network*

Arsitektur NN merupakan pengaturan *neuron* ke dalam lapisan, pola hubungan dalam lapisan, dan di antara lapisan (Fauset, 1994). Arsitektur NN terdiri dari unit input, unit output, dan unit tersembunyi. Secara mendasar, terdapat tiga arsitektur NN (Haykin, 1998):

a. *Single-Layer Feedforward Networks*

Dalam *single-layer Feedforward Networks*, lapisan input langsung menuju ke lapisan output, namun tidak berlaku sebaliknya. Dengan kata lain, arsitektur NN jenis ini secara kuat merupakan tipe *feedforward* atau asiklik (*acyclic*).

b. Multilayer Feedforward Networks

Tipe kedua adalah *multilayer Feedforward Networks* atau dapat disebut juga sebagai *Multilayer Perceptrons* (MLP), dimana yang membedakannya dengan *single-layer Feedforward Networks* adalah pada arsitektur MLP terdapat tambahan satu atau lebih lapisan tersembunyi. Lapisan tersembunyi tersebut berada di antara lapisan input dan lapisan output.

c. Recurrent Networks

Berbeda dengan arsitektur pada *feedforward Neural Networks*, arsitektur *recurrent networks* memiliki satu atau lebih koneksi balik (*feedback loop*). Sebagai contoh, suatu *Recurrent Networks* terdiri dari suatu lapisan dimana setiap *neuron* mengirimkan kembali sinyal output yang dihasilkan sebagai input pada *neuron* lainnya.

2.6.1 Multilayer Perceptrons

Multilayer perceptron (MLP) ditandai dengan adanya minimal satu *hidden layer* pada arsitekturnya, dimana *hidden layer* ini memiliki kemampuan untuk mengenali informasi yang tidak dapat dilihat karena sifat data yang non-linier.

Dalam setiap lapisan terdapat satu atau lebih unit *neuron* yang menerima *input* dari *neuron-neuron* pada lapisan sebelumnya untuk kemudian meneruskan hasil pemrosesan ke *neuron-neuron* pada lapisan sesudahnya. Antar *neuron* dalam satu lapisan yang sama tidak memiliki korelasi. Pada umumnya MLP menggunakan fungsi aktivasi *sigmoid* non linier seperti *bipolar sigmoid* dan hiperolik tangen.

Pada arsitektur MLP, output dihitung melalui persamaan:

$$\hat{Y}_t = f^0 \left(\sum_{j=1}^H w_j^0 \cdot f_j^h \left(\sum_{i=1}^p w_{ji}^h \cdot Y_{t-i} + b_j^h \right) + b^0 \right) \quad (2.36)$$

Dimana

\hat{Y}_t = variabel *output*, sebagai nilai estimasi yang berasal dari variabel *input*

t = indeks data *input-target* (\hat{Y}_{t-i}, \hat{Y}_t), $t = 1, 2, \dots, n$

f^0 = fungsi aktivasi *neuron* pada lapisan *output*

w_j^0 = penimbang *neuron* ke- j pada lapisan tersembunyi yang menuju *neuron* pada lapisan *output*

j = indeks *neuron* pada lapisan tersembunyi, $j = 1, 2, \dots, H$

f_j^h = fungsi aktivasi *neuron* ke- j pada lapisan tersembunyi

w_{ji}^h = penimbang input ke- i yang menuju ke *neuron* j pada lapisan tersembunyi

i = indeks variabel input, $i = 1, 2, \dots, p$

Y_{t-i} = variabel input, sebanyak i

b_j^h = bias *neuron* ke- j pada lapisan tersembunyi, dan

b^0 = bias *neuron* pada lapisan output

2.6.2 Algoritma *Back-Propagation*

Pada umumnya MLP menggunakan algoritma *back propagation* sebagai proses pembelajarannya. *Back propagation* pertama kali diperkenalkan pada tahun 1985 oleh Rumelhart dan Mc Clelland dan telah terbukti pada banyak penelitian, bahwa algoritma ini dapat membuat MLP bekerja dengan lebih efisien (Haykin, 1998). Fungsi aktivasi non linier yang terdapat pada setiap *neuron* dalam lapisan arsitektur MLP ditekankan untuk dapat memenuhi syarat *smooth nonlinearity* dan dapat diturunkan atau *differentiable*.

Fungsi aktivasi nonlinier yang banyak digunakan dalam memenuhi syarat tersebut di atas adalah fungsi *sigmoid*, yang didefinisikan melalui suatu fungsi logistik (Kajitani, 1999):

$$f^h(z) = \frac{1}{1 + e^{-|z|}} \quad (2.37)$$

Nonlinieritas merupakan hal yang penting dalam MLP, karena dengan adanya unsur nonlinieritas ini maka hubungan antara input-output dapat berkurang yang menyebabkan arsitektur yang terbentuk menjadi *single-layer perceptron* (Haykin, 1998).

Algoritma *back-propagation* berdasarkan data *training* $\{(X(n), d(n))\}_{n=1}^N$ dapat diuraikan sebagai berikut (Haykin, 1998):

1. Inisialisasi

Asumsi: tidak ada informasi penunjang sebelumnya

Pilih secara acak dengan nilai yang sangat kecil

2. Jadikan *data training* sebagai input

Pada *network*, tentukan siklus pelatihan (*epoch*) dari *data training*. Untuk setiap set data *training*, lakukan proses komputasi *forward* dan *backward* pada langkah 3 dan 4.

3. Komputasi *forward*

Pembobotan untuk *hidden layer* dan output dengan mengalihkan nilai pada setiap lapisan dengan nilai *weight*, kemudian diperhitungkan dalam fungsi aktivasi yang digunakan.

4. Komputasi *backward*

Perhitungan *error* pada setiap lapisan, dan kemudian dihitung secara mundur dengan tingkat *error* masing-masing lapisan, sesuai dengan *learning rate* yang ditentukan di awal.

5. Iterasi (*epoch*)

Lakukan iterasi terhadap komputasi *forward* dan *backward* pada langkah 3 dan 4 dengan memberikan *epoch* yang baru pada *data training* hingga kriteria STOP terpenuhi.

2.6.3 Hibrida ARIMA-Neural Network (Hibrida ARIMA-NN)

Neural Network merupakan pendekatan yang lebih tepat digunakan untuk pemodelan nonlinier sedangkan ARIMA lebih tepat digunakan untuk pemodelan linier. Namun demikian, seringkali ditemui ketidaktepatan penggunaan masing-masing pendekatan ini di lapangan. Untuk itu pemilihan penggabungan keduanya diharapkan dapat meminimalkan ketidaksesuaian pemilihan metode tersebut.

Adapun model matematisnya dapat ditulis sebagai berikut:

$$\hat{Y}_t = \theta_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} \quad (2.38)$$

Pada penelitian yang dilakukan oleh Zhang (2003), disebutkan bahwa suatu model deret waktu merupakan gabungan model linier dengan nonlinier yang secara matematis ditulis sebagai berikut:

$$Y_t = L_t + N_t \quad (2.39)$$

dimana L_t merupakan komponen linier yang diestimasi dari model ARIMA sehingga residual dari komponen linier hanya mengandung hubungan nonlinier, dan N_t merupakan komponen nonlinier.

Jika ε_t merupakan residual pada waktu t dari model linier yang terbentuk sebelumnya, maka:

$$\varepsilon_t = Y_t - \hat{L}_t \quad (2.40)$$

dimana \hat{L}_t mewakili komponen linier yang merupakan hasil peramalan pada waktu ke- t dari model ARIMA.

Dilanjutkan dengan melakukan pemodelan residual ARIMA menggunakan NN, maka hubungan nonlinier pada model dapat diperoleh. Model NN dengan input residual ARIMA sebanyak p adalah sebagai berikut:

$$\varepsilon_t = f(\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-p}) + a_t \quad (2.41)$$

dimana f merupakan fungsi linier yang ditentukan oleh NN dan a_t merupakan *random error*. Jika model f yang terbentuk tidak sesuai maka a_t tidak akan sepenuhnya acak, sehingga identifikasi model adalah faktor yang sangat penting.

2.6.4 Data Preprocessing dan Data Postprocessing

Tahap *preprocessing* berperan penting dalam NN diantaranya adalah untuk menghindari adanya masalah dalam proses komputasi, untuk memenuhi persyaratan algoritma yang digunakan, dan untuk memberikan fasilitas pembelajaran yang lebih baik sehingga diharapkan mempercepat proses pembelajaran *network*. Proses *scaling* terhadap data deret waktu perlu dilakukan untuk memastikan bahwa input NN yang digunakan berada pada rentang nilai yang digunakan secara internal dalam pemodelan NN. Dalam penelitian ini, penulis menggunakan metode *scaling* secara linier sehingga menghasilkan data deret waktu dalam rentang nilai $[0,1]$ yang diperoleh melalui persamaan berikut:

$$Y_{sv} = \frac{(Y - \min(Y))}{(\max(Y) - \min(Y))} \quad (2.42)$$

dimana

Y : data deret waktu yang sebenarnya

Y_{sv} : data deret waktu hasil *scaling*

$\min(Y)$: nilai minimum dari data deret waktu, dan
 $\max(Y)$: nilai maksimum dari data deret waktu

Proses *scaling* ini dilakukan terhadap data deret waktu yang digunakan dalam penelitian ini yaitu nilai ekspor perikanan Indonesia. Setelah diperoleh output NN, dilakukan *postprocessing* melalui persamaan berikut:

$$Y_0 = Y_{sv}((\max(Y) - \min(Y)) + \min(Y)) \quad (2.43)$$

dimana Y_0 merupakan output data deret waktu yang diperoleh setelah melalui proses pemodelan dan peramalan dengan NN.

2.7 Fuzzy Time series

Fuzzy Time series merupakan suatu teknik peramalan berdasarkan pada logika *fuzzy* dimana hasil yang diperoleh dapat dibahasakan. Watada (1992) menggunakan konsep regresi *fuzzy* pada data deret waktu, atau dikenal dengan analisis regresi *fuzzy time series*, tetapi di dalamnya tidak mengikutsertakan konsep Box-Jenkins. Kemudian metode *Fuzzy-ARIMA* diterapkan pada peramalan perdagangan pasar asing dimana mereka mencoba menggabungkan keunggulan dari regresi *fuzzy* dan metode ARIMA untuk model peramalan yang berupa interval yang lebih baik, dalam arti mengikuti pola data yang diramalkan. Song dan Chissom (1994) mempresentasikan konsep varians waktu dan invarians waktu. Konsep ini diterapkan pada peramalan pendaftaran mahasiswa baru di Universitas Alabama. Beberapa penelitian dan pengembangan metode ini yaitu peramalan dengan metode *fuzzy* pada pendaftaran mahasiswa baru Universitas Alabama menggunakan operasi aritmetika sederhana (Chen, 1996). Model *second order fuzzy* deret waktu untuk meramal pendaftaran mahasiswa di Universitas Alabama (Tsai dan Wu, 1999).

Ada pula yang menggunakan model *high order fuzzy time series* untuk mengatasi kelemahan model *first order fuzzy time series* dengan mengimplementasikan pada peramalan pendaftaran mahasiswa pada Universitas Alabama (Chen, 2002). Model 2 faktor *high-order fuzzy logical relationship* untuk meningkatkan akurasi peramalan dikembangkan oleh Lee, Wang, Chen, dan Leu (2006). Selanjutnya dikembangkan pula metode *high order fuzzy time series* untuk memprediksi temperatur dan peramalan TAIEX (Lee dkk., 2008).

2.7.1 Logika Fuzzy

Logika *fuzzy* merupakan salah satu pembentuk *soft computing*. Logika *fuzzy* pertama kali diperkenalkan oleh Zadeh (1965). Ada beberapa definisi tentang logika *fuzzy*, diantaranya :

- a. Logika *fuzzy* memungkinkan nilai keanggotaan antara 0 dan 1, tingkat keabuan antara hitam dan putih, dalam bentuk linguistik, konsep tidak pasti seperti “sedikit”, ”lumayan” dan “sangat”.
- b. Logika *fuzzy* adalah suatu cara yang tepat untuk memetakan suatu ruang *input* ke dalam suatu ruang *output*, mempunyai nilai kontinu dan logika *fuzzy* dinyatakan dalam derajat dari suatu keanggotaan dan derajat dari kebenaran.
- c. Logika *fuzzy* adalah logika yang digunakan untuk menjelaskan keambiguan, dimana logika *fuzzy* adalah cabang teori dari himpunan *fuzzy*, himpunan yang menyelesaikan keambiguan.
- d. Logika *fuzzy* menyediakan suatu cara untuk merubah pernyataan linguistik menjadi suatu numerik.

2.7.2 Himpunan Fuzzy

Zadeh (1965) menjelaskan bahwa konsep tentang himpunan *fuzzy* (*fuzzy set* = himpunan kabur) yang menyatakan bahwa selain pendekatan probabilitas, ketidakpastian dapat didekati dengan menggunakan metode lain, dalam hal ini konsep himpunan *fuzzy*. Jika X merupakan suatu himpunan dengan anggota-anggotanya dilambangkan dengan x , maka suatu himpunan *fuzzy* A dalam X didefinisikan dengan:

$$A = \{(x, \mu_A(x) | x \in X)\} \quad (2.44)$$

dimana $\mu_A(x)$ disebut fungsi keanggotaan dari himpunan *fuzzy* A , dimana fungsi keanggotaan memetakan tiap elemen dari X pada derajat keanggotaan x pada interval $\{0,1\}$. Nilai dari $\mu_A(x)$ menjelaskan derajat keanggotaan x dalam A , jika $\mu_A(x)$ mendekati 0 maka derajat keanggotaan x dalam A semakin rendah, sebaliknya juga jika $\mu_A(x)$ mendekati 1 maka derajat keanggotaan x dalam A semakin tinggi. Fungsi keanggotaan dari himpunan *fuzzy* yang digunakan adalah fungsi keanggotaan segitiga, persamaan dari fungsi keanggotaan segitiga adalah:

$$\mu_{\beta}(\beta_i) = \begin{cases} 1 - \frac{|\alpha_i - \beta_i|}{c_i}, & \alpha_i - c_i \leq \beta_i \leq \alpha_i + c_i \\ 0, & \text{yang lain} \end{cases} \quad (2.45)$$

Himpunan *fuzzy* memiliki 2 atribut, yaitu :

1. Linguistik yaitu penamaan suatu grup yang mewakili suatu keadaan atau kondisi tertentu dengan menggunakan bahasa alami, seperti: dingin, sejuk, normal, hangat dan panas.
2. Numerik yaitu suatu nilai atau angka yang menunjukkan ukuran dari suatu variabel seperti : 40, 25,50 dan sebagainya.

2.7.3 Dasar-dasar *Fuzzy Time series*

Berbagai definisi dan sifat-sifat peramalan *fuzzy time series* diringkas sebagai berikut :

Definisi 1. Himpunan *fuzzy* merupakan objek kelas-kelas dengan rangkaian kesatuan nilai keanggotaan. Misalkan U adalah *universe of discourse*, $U = \{\mu_1, \mu_2, \dots, \mu_n\}$ dimana μ_i merupakan nilai linguistik yang mungkin dari U kemudian sebuah himpunan *fuzzy* variabel linguistik A_i dari U didefinisikan dengan persamaan 2.16 berikut:

$$A_i = \frac{\mu_{A_i}(\mu_1)}{\mu_1} + \frac{\mu_{A_i}(\mu_2)}{\mu_2} + \dots + \frac{\mu_{A_i}(\mu_n)}{\mu_n} \quad (2.46)$$

Dimana μ_{A_i} merupakan fungsi keanggotaan himpunan *fuzzy* A_i sehingga $\mu_{A_i}: U \rightarrow [0,1]$

Jika μ_j keanggotaan dari A_i maka μ_{A_i} adalah derajat yang dimiliki μ_j terhadap A_i (Singh, 2007).

Definisi 2. Misalkan $Y(t)$ ($t = \dots - 2, -1, 0, 1, 2, \dots$) subset R^1 , menjadi *universe discourse* dengan himpunan *fuzzy* $f_i(t)$ ($i = 1, 2, \dots$) didefinisikan dan $F(t)$ adalah kumpulan dari $f_1(t), f_2(t), \dots$, maka $F(t)$ disebut *fuzzy time series* didefinisikan pada $Y(t)$ ($t = \dots, 0, 1, 2, \dots$). Dari definisi tersebut $F(t)$ dapat dipahami sebagai variabel linguistik $f_i(t)$ ($i = 1, 2, \dots$) dari nilai kemungkinan linguistik $F(t)$.

Karena pada waktu yang berbeda, nilai $F(t)$ dapat berbeda, $F(t)$ sebagai himpunan

fuzzy adalah fungsi dari waktu t dan *universe discourse* berbeda di tiap waktu maka digunakan $Y(t)$ untuk waktu t (Song and Chissom, 1993).

Definisi 3. Misalkan $F(t)$ disebabkan hanya oleh $F(t - 1)$ dan ditunjukkan dengan $F(t - 1) \rightarrow F(t)$ maka ada *Fuzzy Relation* antara $F(t)$ dan $F(t - 1)$ yang diekspresikan dengan rumus :

$$F(t) = F(t - 1) \circ R(t, t - 1) \quad (2.47)$$

dimana “ \circ ” merupakan operator komposisi Max-Min. Relasi R disebut model *first order F(t)*.

Selanjutnya, jika relasi *fuzzy* $R(t, t - 1)$ dari $F(t)$ merupakan independen waktu t sehingga untuk waktu berbeda t_1 dan t_2 , $R(t_1, t_1 - 1) = R(t_2, 2 - 1)$ sehingga $F(t)$ disebut *time-invariant fuzzy time series* (Singh, 2007).

Definisi 4. Misalkan $F(t)$ dihasilkan oleh beberapa himpunan *fuzzy* $F(t - n), F(t - n + 1), \dots, F(t - 1)$ maka hubungan *fuzzy* dilambangkan dengan $A_{i1}, A_{i2}, \dots, A_{in} \rightarrow A_j$ dimana $F(t - n) = A_{i1}, F(t - n + 1) = A_{i2}, \dots, F(t - 1) = A_{in}, F(t) = A_j$ dan hubungan seperti itu disebut model *fuzzy time series* dengan orde ke- n .

Definisi 5. Misalkan $F(t)$ dihasilkan oleh $F(t - 1), F(t - 2), \dots, F(t - m) (m > 0)$ secara simultan dan relasi adalah *time variant* maka $F(t)$ disebut sebagai *time variant fuzzy time series* dan hubungannya dapat diekspresikan dengan rumus:

$$F(t) = F(t - 1) \circ R^W(t, t - 1) \quad (2.48)$$

Dimana $W > 1$ merupakan parameter waktu (bulan atau tahun) yang mempengaruhi ramalan $F(t)$.

2.7.4 Orde Tunggal Weighted Fuzzy Time series

Menurut Song dan Chissom (1994) dan Chen (1996) *fuzzy time series* mengandung operasi matrik yang kompleks dan memiliki pembobot yang sama. Berikut akan diuraikan algoritma menurut Chen, Yu, Cheng, dan Lee.

1. Algoritma Chen

1) Mendefinisikan himpunan sampel ($U = [D_{min}, D_{max}]$) dan interval sebagai gambaran aturan. U dapat dibagi menjadi beberapa bagian dengan panjang interval yang sama $u_1, u_2, u_3, \dots, u_n$. Pada tahap awal, seluruh data dibagi menjadi 7 bagian dengan interval yang sama. Selanjutnya jika terdapat himpunan bagian dengan jumlah anggota lebih besar daripada rata-rata jumlah anggota, maka himpunan tersebut dipartisi lagi dengan interval yang sama (Cheng, Chen, Teoh, & Chiang, 2008).

2) Mendefinisikan himpunan *fuzzy* A_i dari himpunan semesta berdasarkan interval partisi yang dibuat u_i dengan aturan:

$A_1 =$ sangat sangat rendah, $A_2 =$ sangat rendah, $A_3 =$ rendah, dan seterusnya sehingga himpunan *fuzzy* didefinisikan sebagai berikut:

$$A_1 = \frac{a_{11}}{u_1} + \frac{a_{12}}{u_2} + \dots + \frac{a_{1m}}{u_m}$$

$$A_2 = \frac{a_{21}}{u_1} + \frac{a_{22}}{u_2} + \dots + \frac{a_{2m}}{u_m}$$

⋮

$$A_k = \frac{a_{k1}}{u_1} + \frac{a_{k2}}{u_2} + \dots + \frac{a_{km}}{u_m}$$

dimana $a_{ij} \in [0,1]$, $1 \leq i \leq k$ dan $1 \leq j \leq m$. Nilai dari a_{ij} menunjukkan derajat keanggotaan dari u_j dalam himpunan *fuzzy* A_i . Penentuan derajat untuk masing-masing A_i ($i = 1, 2, \dots, m$) yaitu jika keanggotaan maksimum dari suatu data di dalam A_k maka nilai fuzzifikasinya dikatakan sebagai A_k . Karena untuk mendapatkan nilai keanggotaan dalam metode ini menggunakan fungsi keanggotaan segitiga maka diperoleh himpunan *fuzzy* sebagai berikut:

$$A_1 = \frac{1}{u_1} + \frac{0,5}{u_2} + \frac{0}{u_3} + \dots + \frac{0}{u_n}$$

$$A_2 = \frac{0,5}{u_1} + \frac{1}{u_2} + \frac{0,5}{u_3} + \dots + \frac{0}{u_n}$$

Dan seterusnya hingga

$$A_n = \frac{0}{u_1} + \dots + \frac{0,5}{u_{n-1}} + \frac{1}{u_n}$$

- 3) Fuzzifikasikan data historis dimana jika data $x \in u_i$ maka x diubah menjadi himpunan *fuzzy* A_i dimana u_i memiliki nilai keanggotaan maksimum.
- 4) Menentukan *Fuzzy Logical Relationship* (FLR) dan membuat grup sesuai dengan waktu. Contoh, jika FLR berbentuk $A_1 \rightarrow A_2, A_1 \rightarrow A_2, A_1 \rightarrow A_1, A_1 \rightarrow A_3$ maka FLRG-nya adalah $A_1 \rightarrow A_1, A_2, A_3$
- 5) Meramalkan. Misalkan $F(t)$ adalah data yang akan diramalkan, dimana $F(t - 1) = A$, maka nilai ramalan harus sesuai dengan beberapa aturan. Aturan tersebut meliputi:
 - (i) Jika FLR dari A_i tidak ada ($A_i \rightarrow \#$), maka $F(t) = A_i$
 - (ii) Jika hanya terdapat satu FLR (misal $A_i \rightarrow A_j$), maka $F(t) = A_j$
 - (iii) Jika $A_1 \rightarrow A_{j_1}, A_{j_2}, \dots, A_{j_k}$ maka $F(t) = A_{j_1}, A_{j_2}, \dots, A_{j_k}$
- 6) *Defuzzy*. Misalkan $F(t) = A_{j_1}, A_{j_2}, \dots, A_{j_k}$ maka $\hat{y}(t) = \frac{\sum_{p=1}^k m_{jp}}{k}$ dimana $\hat{y}(t)$ merupakan *defuzzy* dan m_{jp} ialah nilai tengah dari A_{jp} dengan kata lain defuzzifikasi $F(t)$ diperoleh dari rata-rata nilai tengah dari masing-masing interval yang memiliki nilai keanggotaan maksimum pada masing-masing A_{j_1}, A_{j_2}, \dots

2. Algoritma Yu

- 1) Mendefinisikan himpunan sampel ($U = [D_{min}, D_{max}]$) dan interval sebagai gambaran aturan. U dapat dibagi menjadi beberapa bagian dengan panjang interval yang sama $u_1, u_2, u_3, \dots, u_n$. Pada tahap awal, seluruh data dibagi menjadi 7 bagian dengan interval yang sama. Selanjutnya jika terdapat himpunan bagian dengan jumlah anggota lebih besar daripada rata-rata jumlah anggota, maka himpunan tersebut dipartisi lagi dengan interval yang sama (Cheng, Chen, Teoh, & Chiang, 2008).
- 2) Mendefinisikan himpunan *fuzzy* A_i dari himpunan semesta berdasarkan interval partisi yang dibuat u_i dengan aturan:
 $A_1 =$ sangat sangat rendah, $A_2 =$ sangat rendah, $A_3 =$ rendah, dan seterusnya sehingga himpunan *fuzzy* didefinisikan sebagai berikut:

$$A_1 = \frac{a_{11}}{u_1} + \frac{a_{12}}{u_2} + \dots + \frac{a_{1m}}{u_m}$$

$$A_2 = \frac{a_{21}}{u_1} + \frac{a_{22}}{u_2} + \dots + \frac{a_{2m}}{u_m}$$

⋮

$$A_k = \frac{a_{k1}}{u_1} + \frac{a_{k2}}{u_2} + \dots + \frac{a_{km}}{u_m}$$

dimana $a_{ij} \in [0,1]$, $1 \leq i \leq k$ dan $1 \leq j \leq m$. Nilai dari a_{ij} menunjukkan derajat keanggotaan dari u_j dalam himpunan fuzzy A_i . Penentuan derajat untuk masing-masing A_i ($i = 1, 2, \dots, m$) yaitu jika keanggotaan maksimum dari suatu data di dalam A_k maka nilai fuzzifikasinya dikatakan sebagai A_k . Karena untuk mendapatkan nilai keanggotaan dalam metode ini menggunakan fungsi keanggotaan segitiga maka diperoleh himpunan fuzzy sebagai berikut:

$$A_1 = \frac{1}{u_1} + \frac{0,5}{u_2} + \frac{0}{u_3} + \dots + \frac{0}{u_n}$$

$$A_2 = \frac{0,5}{u_1} + \frac{1}{u_2} + \frac{0,5}{u_3} + \dots + \frac{0}{u_n}$$

Dan seterusnya hingga

$$A_n = \frac{0}{u_1} + \dots + \frac{0,5}{u_{n-1}} + \frac{1}{u_n}$$

- 3) Fuzzifikasikan data historis dimana jika data $x \in u_i$ maka x diubah menjadi himpunan fuzzy A_i dimana u_i memiliki nilai keanggotaan maksimum.
- 4) Menentukan *Fuzzy Logical Relationship* (FLR) dan membuat grup sesuai dengan waktu. Contoh, jika FLR berbentuk $A_1 \rightarrow A_2, A_1 \rightarrow A_2, A_1 \rightarrow A_1, A_1 \rightarrow A_3$ maka FLRG-nya adalah $A_1 \rightarrow A_1, A_2, A_3$
- 5) Meramalkan. Misalkan $F(t)$ adalah data yang akan diramalkan, dimana $F(t-1) = A$, maka nilai ramalan harus sesuai dengan beberapa aturan. Aturan tersebut meliputi:
 - (iv) Jika FLR dari A_i tidak ada ($A_i \rightarrow \#$), maka $F(t) = A_i$
 - (v) Jika hanya terdapat satu FLR (misal $A_i \rightarrow A_j$), maka $F(t) = A_j$
 - (vi) Jika $A_1 \rightarrow A_{j1}, A_{j2}, \dots, A_{jk}$ maka $F(t) = A_{j1}, A_{j2}, \dots, A_{jk}$

6) *Defuzzy*. Misalkan $F(t) = A_{j_1}, A_{j_2}, \dots, A_{j_k}$ maka matrik *defuzzy* ialah nilai tengah dari $A_{j_1}, A_{j_2}, \dots, A_{j_k}$ yang dapat ditulis

$M(t) = m_{j_1}, m_{j_2}, \dots, m_{j_k}$ dimana $M(t)$ menunjukkan nilai ramalan *defuzzy* dari $F(t)$.

7) Menghitung pembobot. Pembobot dari $F(t) = A_{j_1}, A_{j_2}, \dots, A_{j_k}$ ialah w'_1, w'_2, \dots, w'_k dengan $w'_i = \frac{w_i}{\sum_{n=1}^k w_i}$ dimana $w_1 = 1$ dan $w_i = w_{i-1} + 1$

untuk $2 \leq i \leq k$. Sehingga matrik pembobot dapat ditulis $W(t) =$

$$[w'_1, w'_2, \dots, w'_k] = \left[\frac{1}{\sum_{n=1}^k w_i}, \frac{2}{\sum_{n=1}^k w_i}, \dots, \frac{k}{\sum_{n=1}^k w_i} \right]$$

8) Menghitung nilai ramalan akhir, dihitung dengan rumus $\hat{y}(t) = M(t) \times W(t)^T$

3. Algoritma Cheng

1) Mendefinisikan himpunan sampel ($U = [D_{min}, D_{max}]$) dan interval sebagai gambaran aturan. U dapat dibagi menjadi beberapa bagian dengan panjang interval yang sama $u_1, u_2, u_3, \dots, u_n$. Pada tahap awal, seluruh data dibagi menjadi 7 bagian dengan interval yang sama. Selanjutnya jika terdapat himpunan bagian dengan jumlah anggota lebih besar daripada rata-rata jumlah anggota, maka himpunan tersebut dipartisi lagi dengan interval yang sama (Cheng, Chen, Teoh, & Chiang, 2008).

2) Mendefinisikan himpunan *fuzzy* A_i dari himpunan semesta berdasarkan interval partisi yang dibuat u_i dengan aturan:

$A_1 =$ sangat sangat rendah, $A_2 =$ sangat rendah, $A_3 =$ rendah, dan seterusnya sehingga himpunan *fuzzy* didefinisikan sebagai berikut:

$$A_1 = \frac{a_{11}}{u_1} + \frac{a_{12}}{u_2} + \dots + \frac{a_{1m}}{u_m}$$

$$A_2 = \frac{a_{21}}{u_1} + \frac{a_{22}}{u_2} + \dots + \frac{a_{2m}}{u_m}$$

\vdots

$$A_k = \frac{a_{k1}}{u_1} + \frac{a_{k2}}{u_2} + \dots + \frac{a_{km}}{u_m}$$

dimana $a_{ij} \in [0,1]$, $1 \leq i \leq k$ dan $1 \leq j \leq m$. Nilai dari a_{ij} menunjukkan derajat keanggotaan dari u_j dalam himpunan fuzzy A_i . Penentuan derajat untuk masing-masing $A_i (i = 1,2, \dots, m)$ yaitu jika keanggotaan maksimum dari suatu data di dalam A_k maka nilai fuzzifikasinya dikatakan sebagai A_k . Karena untuk mendapatkan nilai keanggotaan dalam metode ini menggunakan fungsi keanggotaan segitiga maka diperoleh himpunan fuzzy sebagai berikut:

$$A_1 = \frac{1}{u_1} + \frac{0,5}{u_2} + \frac{0}{u_3} + \dots + \frac{0}{u_n}$$

$$A_2 = \frac{0,5}{u_1} + \frac{1}{u_2} + \frac{0,5}{u_3} + \dots + \frac{0}{u_n}$$

Dan seterusnya hingga

$$A_n = \frac{0}{u_1} + \dots + \frac{0,5}{u_{n-1}} + \frac{1}{u_n}$$

- 3) Fuzzifikasikan data historis dimana jika data $x \in u_i$ maka x diubah menjadi himpunan fuzzy A_i dimana u_i memiliki nilai keanggotaan maksimum.
- 4) Menentukan *Fuzzy Logical Relationship* (FLR) dan membuat grup sesuai dengan waktu. Contoh, jika FLR berbentuk $A_1 \rightarrow A_2, A_1 \rightarrow A_2, A_1 \rightarrow A_1, A_1 \rightarrow A_3$ maka FLRG-nya adalah $A_1 \rightarrow A_1, A_2, A_3$
- 5) Meramalkan. Misalkan $F(t)$ adalah data yang akan diramalkan, dimana $F(t-1) = A$, maka nilai ramalan harus sesuai dengan beberapa aturan. Aturan tersebut meliputi:
 - (vii) Jika FLR dari A_i tidak ada ($A_i \rightarrow \#$), maka $F(t) = A_i$
 - (viii) Jika hanya terdapat satu FLR (misal $A_i \rightarrow A_j$), maka $F(t) = A_j$
 - (ix) Jika $A_1 \rightarrow A_{j1}, A_{j2}, \dots, A_{jk}$ maka $F(t) = A_{j1}, A_{j2}, \dots, A_{jk}$
- 6) Menghitung pembobot standar (W_n). Pembobot standar dihitung dengan rumus $W_n(t) = [w'_1, w'_2, \dots, w'_k] = \frac{1}{\sum_{n=1}^k w_i}, \frac{2}{\sum_{n=1}^k w_i}, \dots, \frac{k}{\sum_{n=1}^k w_i}$
- 7) Menghitung nilai ramalan yang sesuai dengan $F(t) = L_{df}(t-1) \cdot W_n(t-1)$ dimana $L_{df}(t-1)$ ialah matrik defuzzy dan $W_n(t-1)$ ialah matrik pembobot.

4. Algoritma Lee

1) Mendefinisikan himpunan sampel ($U = [D_{min}, D_{max}]$) dan interval sebagai gambaran aturan. U dapat dibagi menjadi beberapa bagian dengan panjang interval yang sama $u_1, u_2, u_3, \dots, u_n$. Pada tahap awal, seluruh data dibagi menjadi 7 bagian dengan interval yang sama. Selanjutnya jika terdapat himpunan bagian dengan jumlah anggota lebih besar daripada rata-rata jumlah anggota, maka himpunan tersebut dipartisi lagi dengan interval yang sama (Cheng, Chen, Teoh, & Chiang, 2008).

2) Mendefinisikan himpunan *fuzzy* A_i dari himpunan semesta berdasarkan interval partisi yang dibuat u_i dengan aturan:

$A_1 =$ sangat sangat rendah, $A_2 =$ sangat rendah, $A_3 =$ rendah, dan seterusnya sehingga himpunan *fuzzy* didefinisikan sebagai berikut:

$$A_1 = \frac{a_{11}}{u_1} + \frac{a_{12}}{u_2} + \dots + \frac{a_{1m}}{u_m}$$

$$A_2 = \frac{a_{21}}{u_1} + \frac{a_{22}}{u_2} + \dots + \frac{a_{2m}}{u_m}$$

⋮

$$A_k = \frac{a_{k1}}{u_1} + \frac{a_{k2}}{u_2} + \dots + \frac{a_{km}}{u_m}$$

dimana $a_{ij} \in [0,1]$, $1 \leq i \leq k$ dan $1 \leq j \leq m$. Nilai dari a_{ij} menunjukkan derajat keanggotaan dari u_j dalam himpunan *fuzzy* A_i . Penentuan derajat untuk masing-masing A_i ($i = 1, 2, \dots, m$) yaitu jika keanggotaan maksimum dari suatu data di dalam A_k maka nilai fuzzifikasinya dikatakan sebagai A_k . Karena untuk mendapatkan nilai keanggotaan dalam metode ini menggunakan fungsi keanggotaan segitiga maka diperoleh himpunan *fuzzy* sebagai berikut:


$$A_1 = \frac{1}{u_1} + \frac{0,5}{u_2} + \frac{0}{u_3} + \dots + \frac{0}{u_n}$$

$$A_2 = \frac{0,5}{u_1} + \frac{1}{u_2} + \frac{0,5}{u_3} + \dots + \frac{0}{u_n}$$

Dan seterusnya hingga

$$A_n = \frac{0}{u_1} + \dots + \frac{0,5}{u_{n-1}} + \frac{1}{u_n}$$

- 3) Fuzzifikasikan data historis dimana jika data $x \in u_i$ maka x diubah menjadi himpunan fuzzy A_i dimana u_i memiliki nilai keanggotaan maksimum.
- 4) Menentukan *Fuzzy Logical Relationship* (FLR) dan membuat grup sesuai dengan waktu. Contoh, jika FLR berbentuk $A_1 \rightarrow A_2, A_1 \rightarrow A_2, A_1 \rightarrow A_1, A_1 \rightarrow A_3$ maka FLRG-nya adalah $A_1 \rightarrow A_1, A_2, A_3$
- 5) Meramalkan. Misalkan $F(t)$ adalah data yang akan diramalkan, dimana $F(t - 1) = A$, maka nilai ramalan harus sesuai dengan beberapa aturan. Aturan tersebut meliputi:
 - (x) Jika FLR dari A_i tidak ada ($A_i \rightarrow \#$), maka $F(t) = A_i$
 - (xi) Jika hanya terdapat satu FLR (misal $A_i \rightarrow A_j$), maka $F(t) = A_j$
 - (xii) Jika $A_1 \rightarrow A_{j_1}, A_{j_2}, \dots, A_{j_k}$ maka $F(t) = A_{j_1}, A_{j_2}, \dots, A_{j_k}$
- 6) *Defuzzy*. Misalkan $F(t) = A_{j_1}, A_{j_2}, \dots, A_{j_k}$ maka matrik *defuzzy* ialah nilai tengah dari $A_{j_1}, A_{j_2}, \dots, A_{j_k}$ yang dapat ditulis $M(t) = m_{j_1}, m_{j_2}, \dots, m_{j_k}$ dimana $M(t)$ menunjukkan nilai ramalan *defuzzy* dari $F(t)$.
- 7) Menghitung pembobot standar (W_n). Pembobot standar dihitung dengan rumus $W_n(t) = [w'_1, w'_2, \dots, w'_k] = \left[\frac{1}{\sum_{n=1}^k W_i}, \frac{2}{\sum_{n=1}^k W_i}, \dots, \frac{k}{\sum_{n=1}^k W_i} \right]$
- 8) Menghitung nilai ramalan akhir, dihitung dengan rumus $\hat{y}(t) = M(t) \times W(t)^T$



BAB 3

METODOLOGI PENELITIAN

Pada bab ini akan dijelaskan mengenai metodologi penelitian yang meliputi sumber data, variabel yang digunakan, dan metode analisis yang terdiri dari atas tahapan-tahapan penelitian yang akan dilakukan. Metode yang akan digunakan dalam penelitian ini adalah ARIMA-WFTS yang merupakan penggabungan antara peramalan melalui metode ARIMA dengan peramalan melalui metode WFTS, serta ARIMA-NN yang merupakan penggabungan antara peramalan dengan metode ARIMA dengan peramalan melalui metode FFNN. Selanjutnya, kinerja dari pemodelan peramalan dengan menggunakan metode ARIMA-WFTS akan dibandingkan dengan peramalan menggunakan metode ARIMA-NN.

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang berasal dari Badan Pusat Statistik (BPS) yakni data bulanan nilai ekspor perikanan Indonesia. Data volume ekspor perikanan Indonesia terbagi ke dalam 8 kelompok komoditi ekspor berdasarkan kode HS 4 digit.

Data ekspor yang diterbitkan oleh BPS dikumpulkan berdasarkan dokumen ekspor atau Pemberitahuan Ekspor Barang (PEB) yang diisi oleh eksportir dan telah diberi ijin muat oleh Kantor Pelayanan Bea dan Cukai, dan selanjutnya dikirim ke BPS dan Bank Indonesia (BI).

Pada proses analisis, data akan dibagi menjadi dua bagian yaitu data *training* untuk pembentukan model dan data *testing* untuk validasi dan pemilihan model terbaik. Data periode Januari 1999 sampai dengan Desember 2012 digunakan sebagai data *training (in-sample)* dan data periode Januari 2013 sampai dengan Juli 2015 sebagai data *testing (out-sample)*.

3.2 Variabel Penelitian

Berdasarkan latar belakang dan tujuan penelitian, maka penelitian ini menggunakan data bulanan total volume ekspor perikanan Indonesia serta volume ekspor masing-masing kelompok komoditi perikanan. Periode data ekspor perikanan Indonesia yang digunakan adalah pada rentang waktu bulan Januari 1999 sampai dengan Desember 2012 sebagai data *training (in-sample)* dan Januari 2013 sampai dengan Juli 2015 sebagai data *testing (out-sample)*.

Berdasarkan pengelompokan kode HS 4 digit (*Harmonized System*), sektor perikanan terdiri dari 8 (delapan) kelompok komoditi dengan komoditi yang berperan sebagai kontributor terbesar selama periode Januari 1999 – Juli 2015 adalah kelompok komoditi 0302, 0303, dan 0306 dengan perincian sebagai berikut:

Tabel 3.1 Rincian Jenis Komoditi per kelompok komoditi Unggulan Ekspor Perikanan Indonesia

0302	0303	0306
Pacific Salmon Frozen	Fish fillets fresh or chilled	Oysters fit for human consumption
Trout Frozen	Other fish fillets of marine fish fresh or chilled	Scallops live, fresh or chilled
Atlantic Salmon frozen	Other fish fillets oth than marinefish	Scallops frozen
other salmonide frozen	fresh or chilled	Scallops other than frozen
Halibut frozen	Frozen fillets	Mussels live, fresh or chilled
Plaice frozen	Other fish meat of marine fish	Mussels frozen
Sole frozen	Oth fish meat oth than marine fish	Mussels other than frozen
Other flat fish frozen		Cuttle fish live, fresh or chilled
Alacore or longfinned tunas forzen		Cuttle fish frozen
Yellowfin tunas forzen		Cuttle fish other than frozen
Skipjack or stripe-bellied bonito frozen		Octopus live, fresh or chilled
Other tunas fish frozen		Octopus frozen
Herrings frozen		Octopus other than frozen
Cod frozen		Snails, other than sea nails
		Live, fresh or chilled of other mollusca
		Jelly fish frozen
		Other molluscs frozen

Sumber: BPS

3.3 Tahapan Analisis

Metode analisis yang digunakan sebagai langkah-langkah untuk mencapai tujuan penelitian dijabarkan dalam tahap-tahap sebagai berikut:

3.3.1 Tahap Awal

Pada tahap awal, ditentukan jumlah data *training* sebagai *in-sample* dan data *testing* sebagai *out-sample*.

3.3.2 Pemodelan dengan Metode ARIMA

Pemodelan dengan metode ARIMA dilakukan untuk total volume ekspor perikanan, selanjutnya dilakukan pengujian melalui prosedur Box-Jenkins.

Langkah-langkah yang dilakukan sebagai berikut:

- (i) Mencari model terpilih ARIMA
- (ii) Plot deret waktu dari data *training*, dan plot ACF/PACF hasil berdasarkan informasi model ARIMA
- (iii) Estimasi parameter model ARIMA (p,d,q), untuk melihat bagaimana hasil uji signifikansi parameter berdasarkan model terpilih
- (iv) Melakukan diagnostic check untuk *white noise* dan normalitas residual melalui uji Ljung-Box dan Kolmogorv-Smirnov
- (v) Peramalan volume ekspor
- (vi) Menghitung nilai RMSE dan MAPE dari data *training* dan data *testing*

3.3.3 Pemodelan dengan Metode FFNN

Pemodelan dengan metode FFNN dilakukan terhadap total volume ekspor perikanan dengan langkah-langkah sebagai berikut:

- (i) Jumlah *neuron* pada lapisan input ditentukan sebanyak *lag autoregressive* yang signifikan pada data *training*
- (ii) Penentuan jumlah *neuron* pada *hidden layer* untuk pemodelan, diawali dengan 1 (satu) buah *hidden neuron*
- (iii) Menentukan fungsi aktivasi
- (iv) Pembelajaran jaringan untuk mendapatkan model FFNN
- (v) Peramalan volume ekspor
- (vi) Menghitung nilai RMSE dan MAPE dari data *training* dan data *testing*

Uji kesesuaian jumlah *neuron* pada lapisan tersembunyi untuk memperoleh model FFNN terbaik dilakukan melalui tahapan:

- (i) Uji pemodelan FFNN dengan variasi jumlah *neuron* sebanyak 1 sampai dengan 10 *hidden neuron*, yang telah melalui 5x percobaan per *hidden neuron* dengan *initial weight* yang berbeda
- (ii) Analisis besaran nilai RMSE dan MAPE pada data *testing* sebagai dasar dalam pemilihan model FFNN terbaik

3.3.4 Pemodelan hibrida ARIMA-NN

Pemodelan hibrida ARIMA-NN dilakukan dengan langkah-langkah sebagai berikut:

- (i) Pemodelan dengan ARIMA untuk memperoleh model linier terbaik, berdasarkan langkah-langkah pada bagian 3.3.2
- (ii) Mendapatkan residual dari model linier ARIMA, berdasarkan persamaan:

$$\varepsilon_t = Y_t - \hat{L}_t$$

- (iii) Pemodelan NN dengan menggunakan residual dari langkah (i) sebagai *neuron* input, berdasarkan persamaan:

$$\varepsilon_t = f(\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-p}) + a_t$$

- (iv) Pemodelan dengan *hybrid forecasting* dari langkah (i) dan langkah (iii) berdasarkan persamaan:

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t$$

- (v) Peramalan volume ekspor perikanan Indonesia
- (vi) Menghitung nilai RMSE dan MAPE dari *data training* dan *data testing*

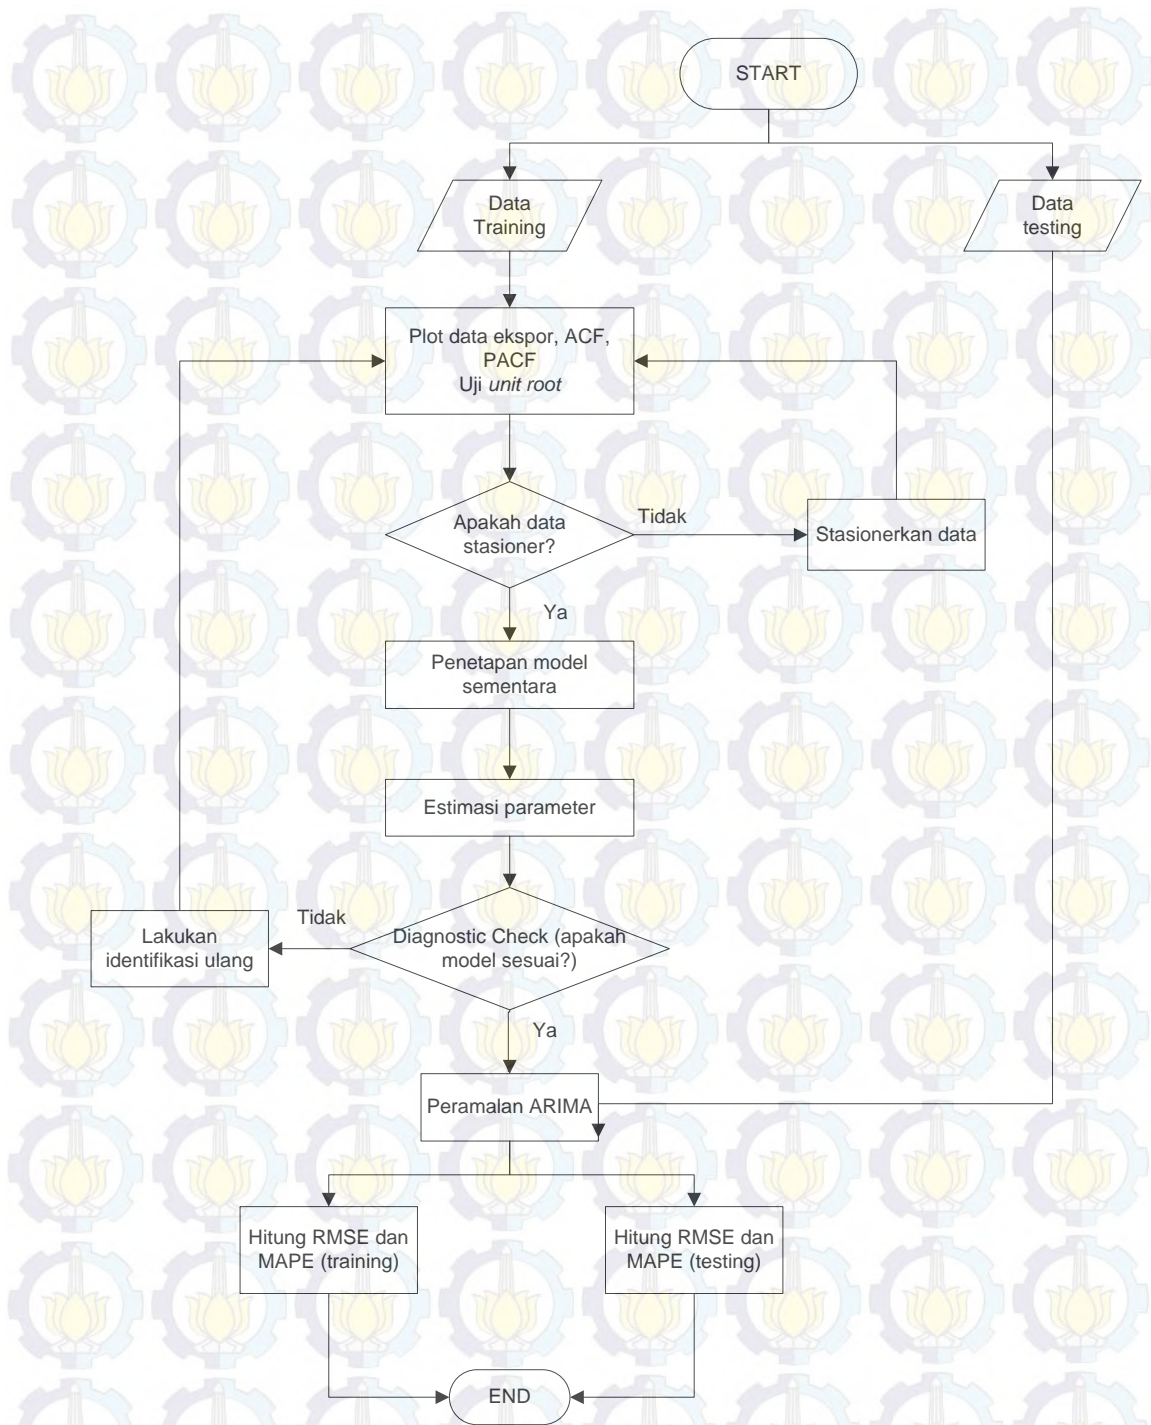
3.3.5 Pemodelan dengan WFTS

Pemodelan dengan metode WFTS dilakukan sebagai berikut:

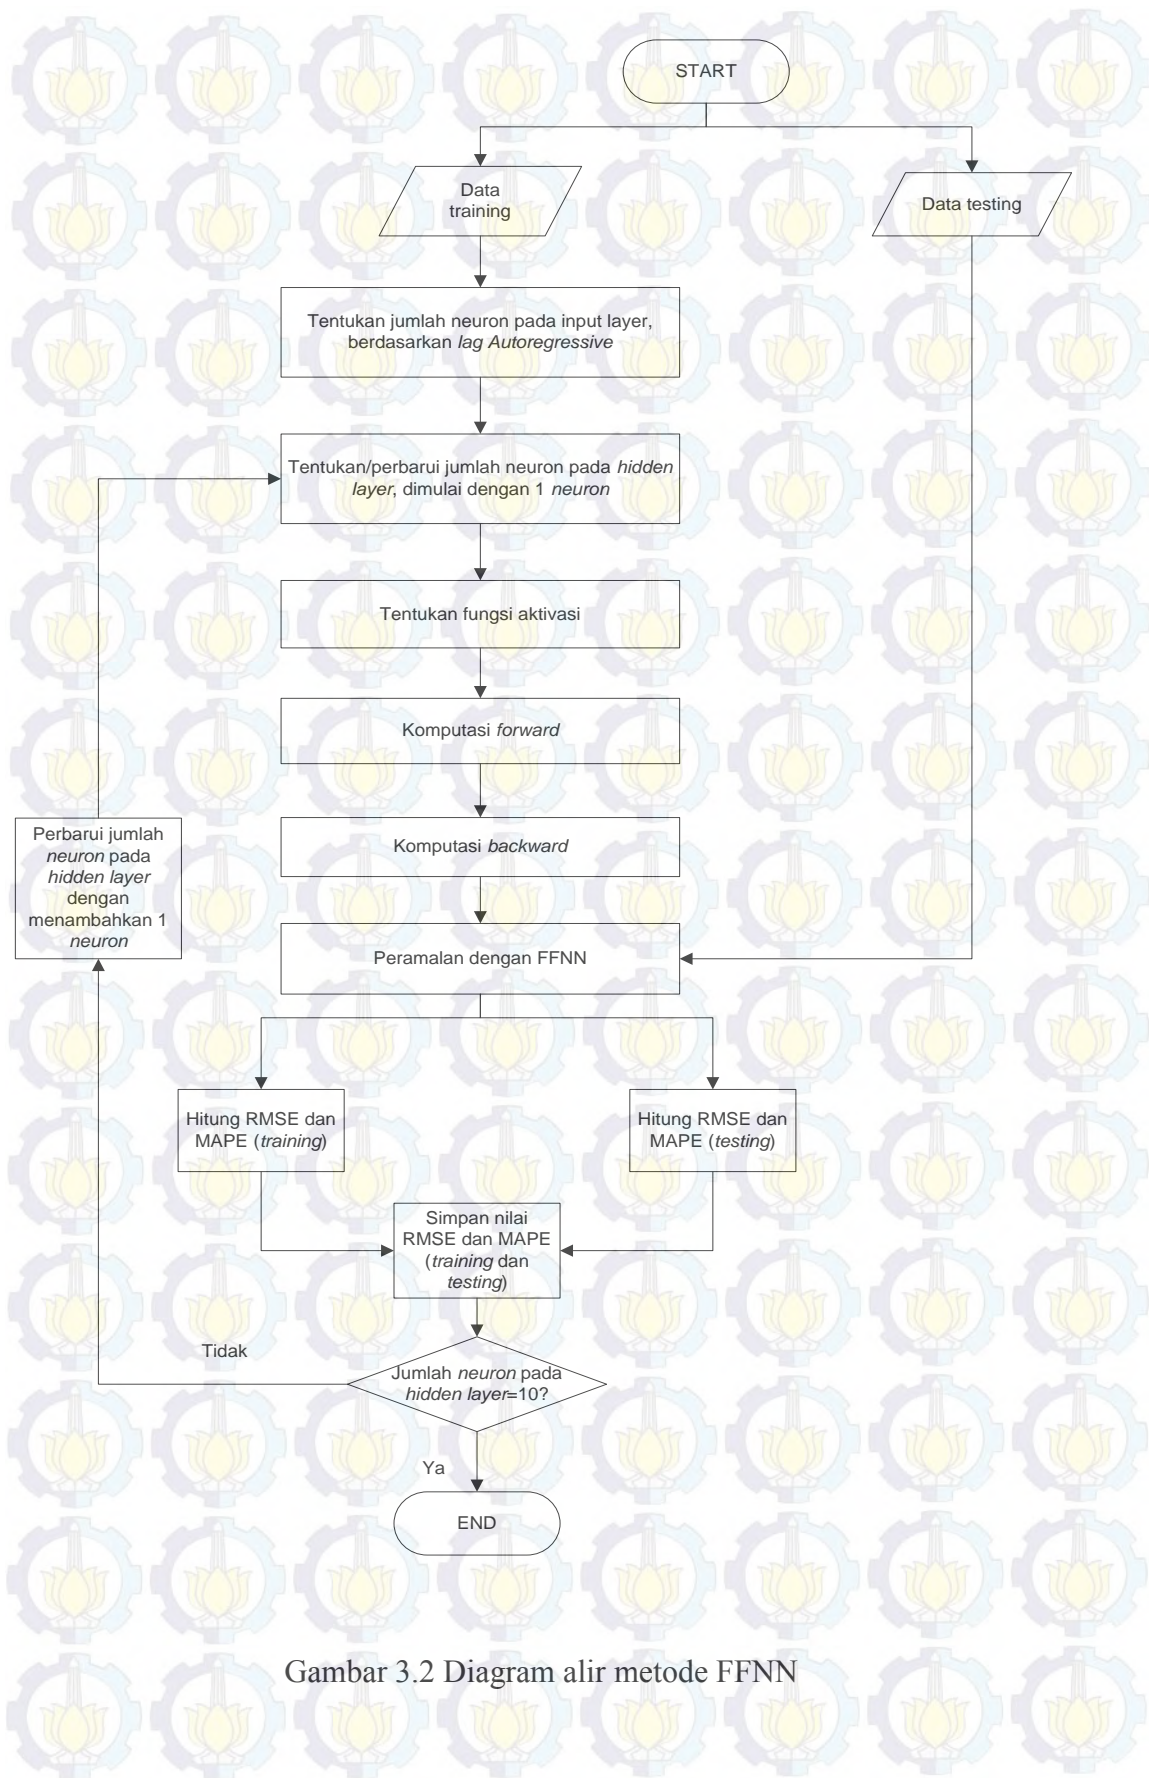
- (i) Mengaplikasikan metode WFTS sesuai dengan algoritma Chen, Yu, Cheng, dan Lee. Langkah ini digunakan untuk mendapatkan orde terbaik dari metode WFTS yang sesuai untuk peramalan volume ekspor perikanan Indonesia.
- (ii) Peramalan volume ekspor perikanan Indonesia
Menghitung nilai RMSE dan MAPE

3.3.6 Analisis Kinerja Peramalan

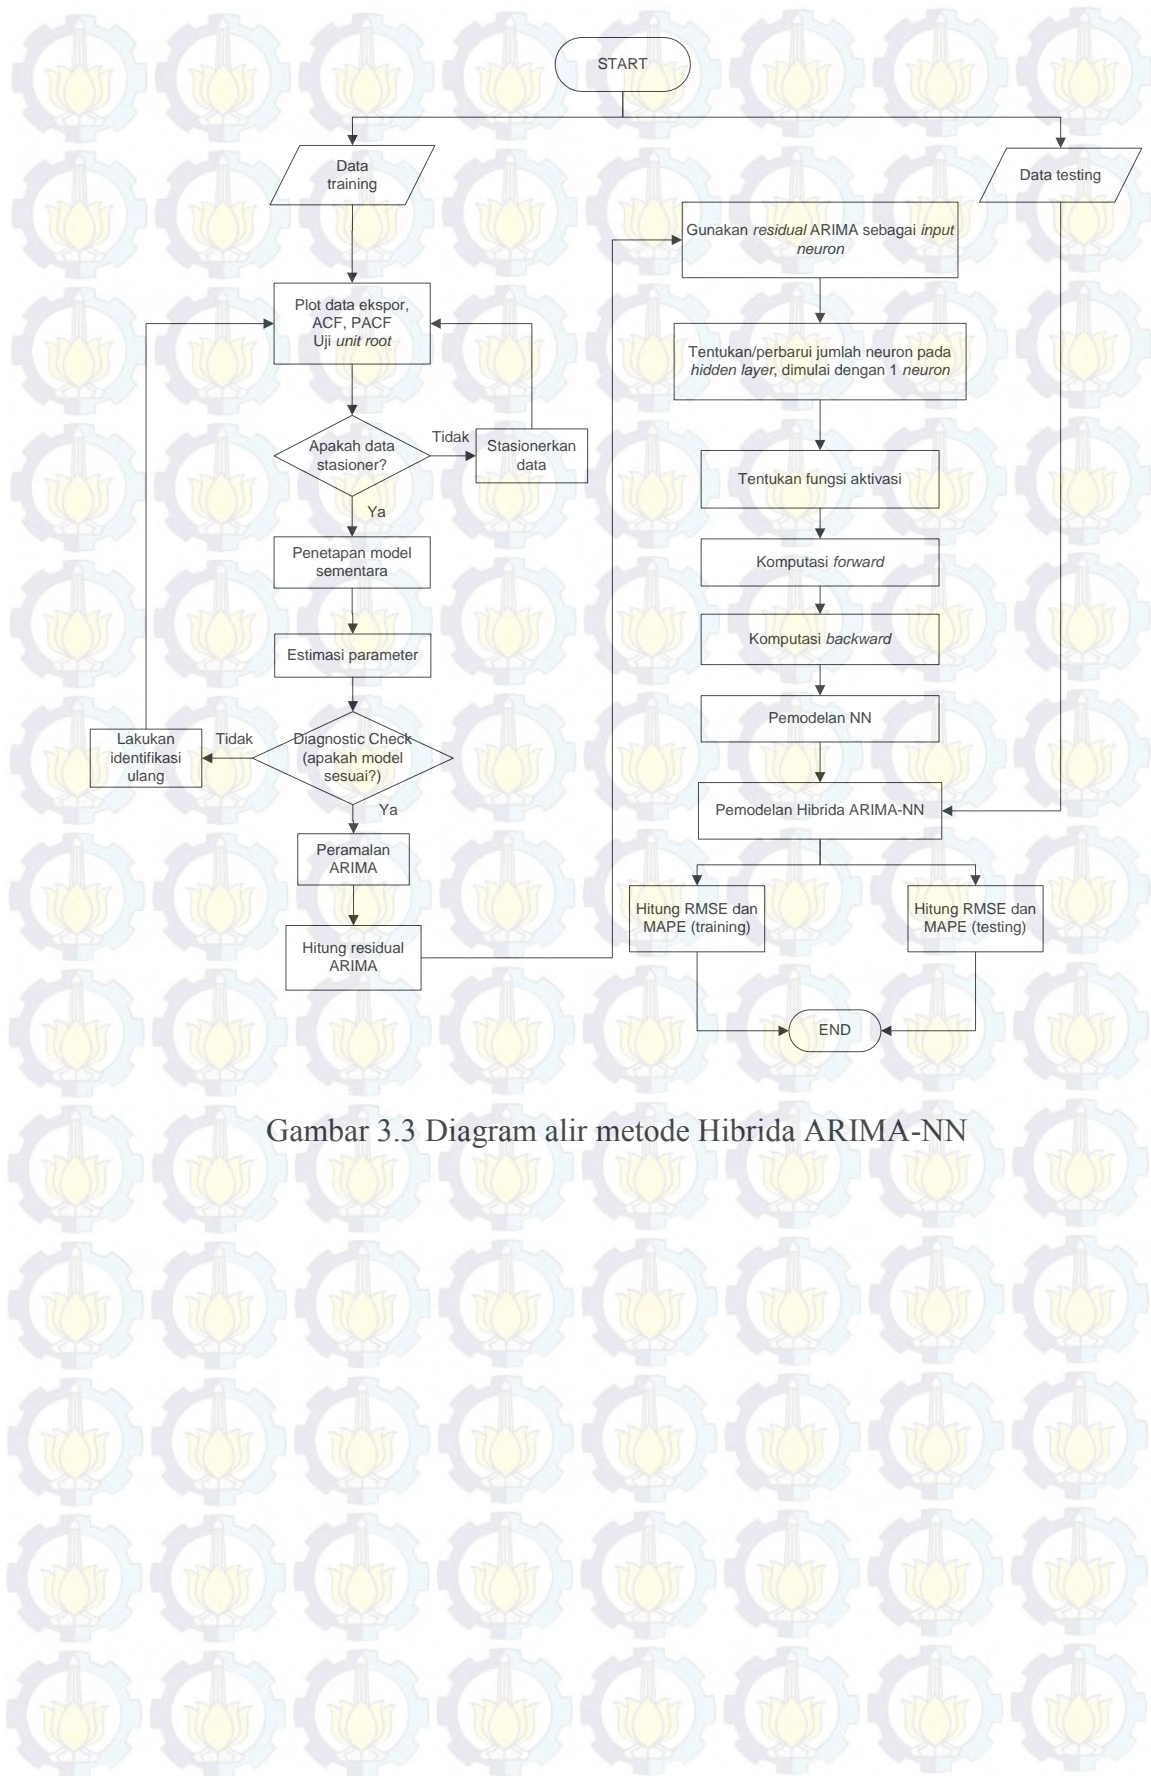
Untuk mengetahui kinerja peramalan dilakukan perbandingan nilai RMSE dan MAPE dari pemodelan dengan metode ARIMA, FFNN, hibrida ARIMA-NN dan WFTS. Perbandingan nilai RMSE dan MAPE ini dilakukan pada data *testing*.



Gambar 3.1 Diagram alir metode ARIMA melalui prosedur Box-Jenkins



Gambar 3.2 Diagram alir metode FFNN



Gambar 3.3 Diagram alir metode Hibrida ARIMA-NN



BAB 4

ANALISIS DAN PEMBAHASAN

Pada bab ini dilakukan analisis terhadap data volume ekspor perikanan Indonesia untuk menjawab tujuan dari penelitian mengenai mendapatkan model peramalan yang terbaik dari metode ARIMA, FFNN, Hibrida ARIMA-NN, dan *Weighted Fuzzy Time series*. Data ekspor perikanan terbagi ke dalam 8 (delapan) kelompok komoditi (berdasarkan 4 digit kode HS). Namun demikian, analisis pada bab ini hanya akan dilakukan terhadap 3 (tiga) kelompok komoditi ekspor perikanan yang memberikan kontribusi terbesar terhadap sektor perikanan.

4.1 Gambaran Umum Ekspor Perikanan Indonesia

Untuk mengetahui gambaran umum ekspor perikanan Indonesia, dilakukan analisis deskriptif.


Tabel 4.1 Statistik Deskriptif Volume Ekspor Perikanan untuk Kelompok Komoditi 302,303, dan 306 periode Januari 1999-Juli 2015

(dalam kg)

Kode HS	Rata-rata	StDev	Minimum	Maksimum
302	8,008,089	2,383,956	4,286,619	18,581,130
303	24,487,190	20,460,787	2,571,709	154,422,600
306	11,584,243	1,774,249	5,695,443	17,341,013
total all	55,203,351	23,116,462	20,996,995	184,775,267

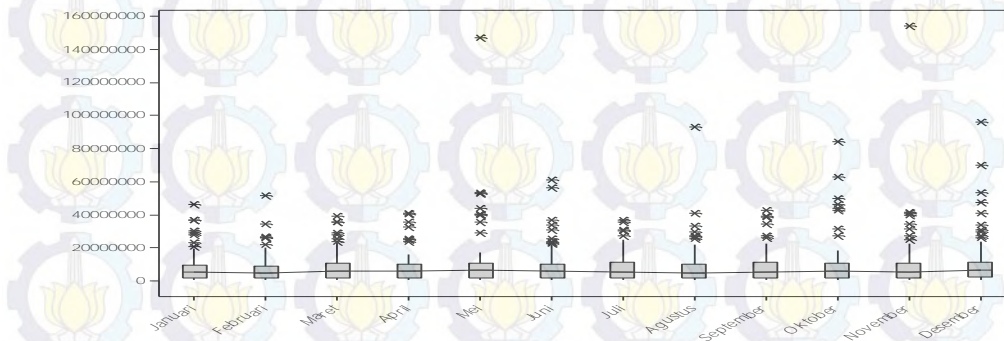
Sumber: BPS, diolah

Tabel 4.1 menyajikan deskriptif dari data untuk masing-masing kelompok komoditi unggulan beserta total volume ekspor perikanan selama periode Januari 1999 – Juli 2015.



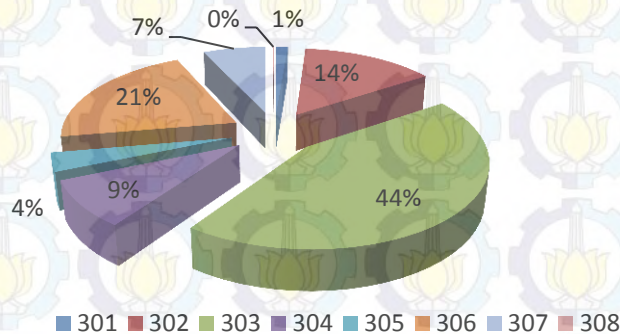
Gambar 4.1 Rata-rata Bulanan Volume Ekspor Perikanan Indonesia

Gambar 4.1 dengan jelas memperlihatkan bahwa rata-rata bulanan terendah dari volume ekspor perikanan selama periode Januari 1999 - Juli 2015 berada pada bulan Februari, sedangkan rata-rata tertinggi berada pada bulan Desember.



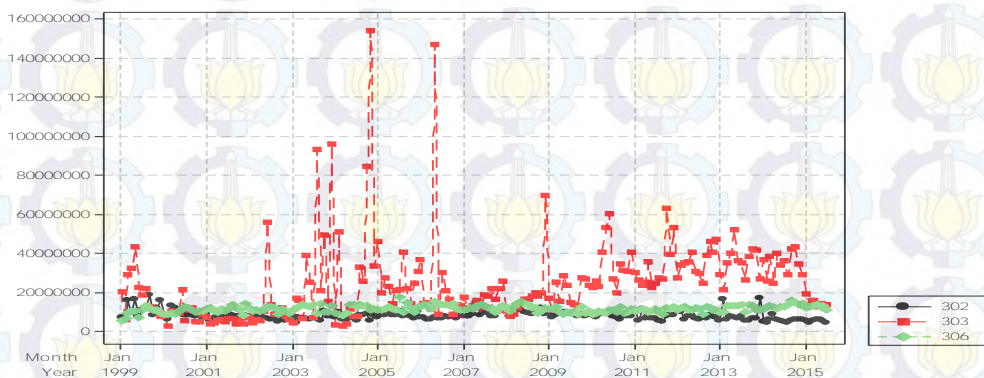
Gambar 4.2 Box Plot untuk Rata-rata Bulanan Volume Ekspor Perikanan Indonesia

Melalui gambar 4.2 yang menyajikan Box Plot untuk rata-rata bulanan volume ekspor perikanan Indonesia, terlihat bahwa terdapat sejumlah nilai yang terdapat pada bagian atas *whiskers* pada setiap bulan yang mengindikasikan adanya *outlier*. Jika diperhatikan dengan seksama, *outlier* yang cukup ekstrim terdapat pada bulan Mei dan November. Sementara itu, nilai median pada setiap bulan terlihat hampir sejajar atau tidak jauh berbeda satu sama lain. Panjang *whiskers* yang berbeda antara bagian atas dan bawah kotak (*box*) juga mengindikasikan bahwa data volume ekspor per bulan tidak simetris, dengan kata lain tidak berdistribusi normal.



Gambar 4.3 Kontribusi Masing-masing Kelompok Komoditi terhadap Ekspor Perikanan

Gambar 4.3 secara visual memperlihatkan kontribusi masing-masing kelompok komoditi perikanan terhadap total volume ekspor perikanan Indonesia. Secara berurutan, kelompok komoditi 303, 306, dan 302 merupakan tiga kelompok komoditi dengan kontribusi terbesar. Kelompok komoditi 303 menyumbang sebesar 44 persen, sedangkan kelompok komoditi 306 dan 302 masing-masing memberikan kontribusi sebesar 21 dan 14 persen, sehingga total kontribusi dari ketiga kelompok komoditi ini adalah sebesar 79 persen terhadap volume ekspor perikanan Indonesia. Perkembangan ekspor ketiga kelompok komoditi unggulan ekspor perikanan dapat dilihat pada gambar berikut:



Gambar 4.4 Perkembangan Ekspor Perikanan Indonesia untuk komoditi unggulan


Gambar 4.4 menyajikan perkembangan perkembangan volume ekspor perikanan Indonesia bulanan untuk ketiga komoditi unggulan, yakni kelompok komoditi 302, 303, dan 306 pada periode Januari 1999 sampai dengan Juli 2015. Pola data untuk kelompok komoditi 303 terlihat lebih fluktuatif disertai dengan sejumlah peningkatan yang cukup signifikan pada beberapa titik waktu tertentu jika dibandingkan dengan dua kelompok komoditi lainnya. Sedangkan pola data untuk kelompok komoditi 302 dan 306 cenderung bergerak konstan dari tahun ke tahun.

4.2 Kelompok Komoditi 302

4.2.1 Pemodelan dengan Metode ARIMA

Pada bagian ini disajikan bagaimana memperoleh model ARIMA terbaik menurut prosedur Box-Jenkins untuk keperluan peramalan.

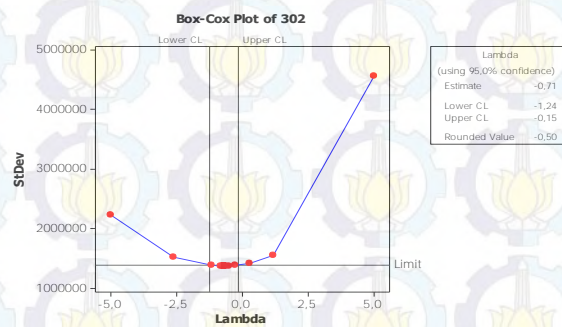
1. Plot data *training* Januari 1999 s.d Desember 2012



Gambar 4.5 Plot Data *Training* Volume Ekspor Perikanan Kelompok Komoditi 302

Plot data *training* untuk kelompok komoditi 302 memperlihatkan tidak adanya pola tren sehingga dapat diambil dugaan awal bahwa pola data tersebut telah stasioner dalam *mean* (rata-rata). Untuk menguji stasioneritas dalam varians dan *mean*, akan dilakukan transformasi Box-Cox dan uji ADF.

2. Transformasi Box-Cox dan Uji Unit Root ADF



Gambar 4.6 Box-Cox Plot untuk Kelompok Komoditi 302

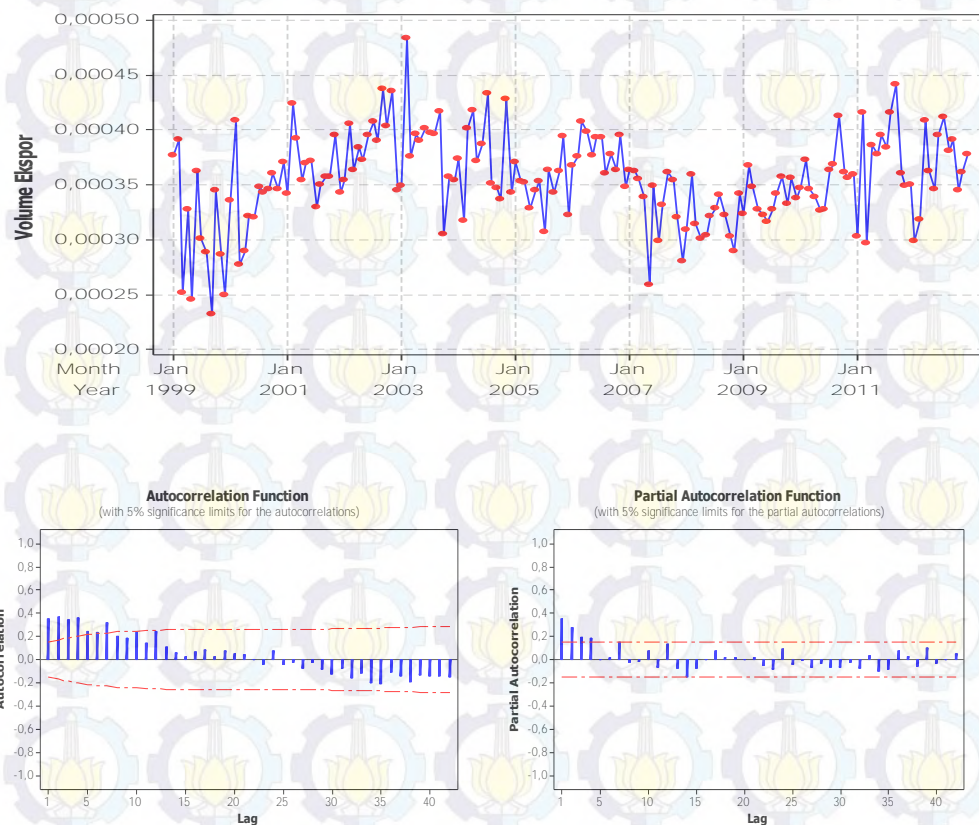
Berdasarkan plot Box-Cox, terlihat nilai lambda sebesar $-0,50$. Hal ini berarti untuk mencapai stasioneritas dalam varians, perlu dilakukan transformasi satu per akar kuadrat terhadap data kelompok komoditi 302. Selanjutnya, berdasarkan hasil uji ADF pada tabel 4.2, terlihat bahwa plot data untuk kelompok komoditi 302 terbukti telah stasioner pada level sehingga tidak perlu dilakukan

differencing. Dengan kata lain, plot data pada kelompok komoditi 302 telah stasioner dalam *mean*.

Tabel 4.2 Hasil Uji Augmented Dickey-Fuller Data Volume Ekspor Perikanan Kelompok Komoditi 302

Parameter	Estimasi	Std Error	τ_{hitung}	$\tau_{tabel (5\%)}$	p-value	Keputusan
δ	-0,366254	0,088983	-4,114988	-2,878937	0,0012	Tolak H_0

3. Plot data *training*, ACF, dan PACF setelah transformasi



Gambar 4.7 Plot data dan pola ACF, PACF sesudah transformasi

Gambar 4.7 secara visual memperlihatkan pola data sesudah dilakukan transformasi telah stasioner, baik dalam *mean* maupun dalam varians. Melalui pola ACF, terlihat adanya pola *dies down*. Sedangkan pola PACF juga menunjukkan pola *dies down*. Dengan demikian dugaan awal untuk model pada kelompok komoditi 302 adalah ARMA (p,q). Selanjutnya dilakukan pengujian

parameter dan cek diagnosa terhadap sejumlah kemungkinan model yang terbentuk sesuai dugaan awal.

4. Estimasi Parameter dan Diagnostic Check

Tabel 4.3 Uji Estimasi Parameter dan Cek Diagnosa

Model	Estimasi Parameter	AIC	SBC	L-Jung Box	Normality
(1,0,0)	sig	-2939,25	-2933,01	Tdk <i>white noise</i>	normal
(2,0,0)	sig	-2950,49	-2941,12	Tdk <i>white noise</i>	normal
(3,0,0)	sig	-2954,55	-2942,05	<i>White noise</i>	normal
(4,0,0)	sig	-2958,19	-2942,57	<i>White noise</i>	normal
(1,0,1)	sig	-2961,14	-2951,77	<i>White noise</i>	normal
(4,0,3)	sig	-2958,84	-2933,85	<i>White noise</i>	normal
(1,0,[7])	sig	-2948,96	-2939,58	Tdk <i>white noise</i>	normal
(2,0,[7])	sig	-2958,76	-2946,27	<i>White noise</i>	normal

Melalui tabel 4.3, model terbaik ditentukan berdasarkan nilai RMSE minimum untuk model yang memenuhi asumsi *white noise* dan berdistribusi normal, yaitu ARIMA (1,0,1).

Hasil pengujian parameter terhadap model terbaik ARIMA (1,0,1) dapat dilihat pada tabel 4.4 berikut:

Tabel 4.4 Estimasi Parameter dan Uji Signifikansi ARIMA (1,0,1)

Parameter	Estimasi	p-value	keputusan
MU	0.0003549	<.0001	signifikan
MA1,1	0.74223	<.0001	signifikan
AR1,1	0.9367	<.0001	signifikan

Tabel 4.5 Nilai Statistik Uji Chi-Square Residual ARIMA (1,0,1)

Lag	Chi-Square	DF	p-value	keputusan
6	2.64	4	0.62	<i>white noise</i>
12	11.04	10	0.3548	<i>white noise</i>
18	15.58	16	0.4824	<i>white noise</i>
24	20.8	22	0.533	<i>white noise</i>
30	22.82	28	0.7418	<i>white noise</i>
36	31.17	34	0.6072	<i>white noise</i>
42	33.6	40	0.7525	<i>white noise</i>
48	37.7	46	0.8033	<i>white noise</i>

Berdasarkan tabel 4.5, nilai p-value dari statistik uji Chi-Square pada lag 6 sampai dengan lag 48 lebih besar dari 0,05. Hal ini berarti data sudah memenuhi asumsi *white noise*. Pengujian terhadap asumsi normalitas dilakukan dengan uji Kolmogorv Smirnov. Hasil pengujian pada tingkat signifikansi 5 persen memberikan nilai statistik uji D sebesar lebih dari 0,1500, yang berarti residual berdistribusi normal. Dengan demikian model ARIMA (1,0,1) telah memenuhi syarat sebagai model terbaik untuk kelompok komoditi 302. Secara matematis, model ARIMA (1,0,1) dapat ditulis dengan persamaan sebagai berikut:

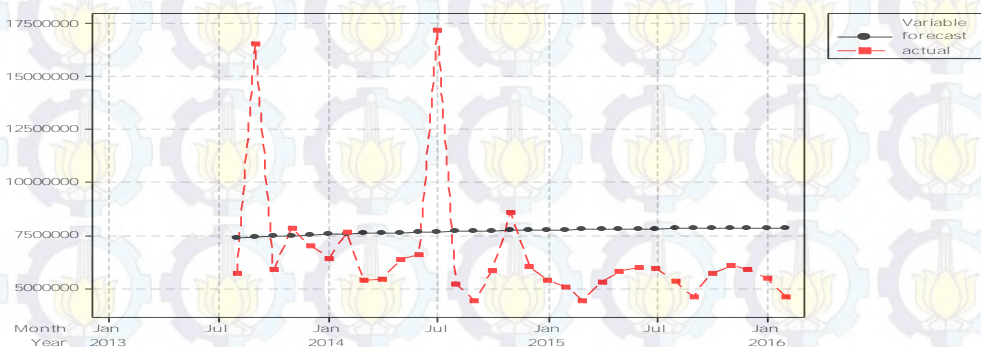
$$Z_t = \theta_0 + \phi_1 Z_{t-1} - \theta_1 e_{t-1} + e_t$$

Dengan memasukkan nilai parameter, maka persamaan diatas menjadi:

$$Z_t = 0,0004 + 0,94Z_{t-1} - 0,74e_{t-1} + e_t$$


Model diatas menjelaskan bahwa besarnya volume ekspor perikanan untuk kelompok komoditi 302 berkaitan dengan volume ekspor pada bulan sebelumnya.

5. Peramalan dengan model ARIMA terbaik



Gambar 4.8 Perbandingan hasil peramalan dan nilai aktual dari *outsample* pada kelompok komoditi 302

Secara visual, gambar 4.8 memperlihatkan peramalan model ARIMA dibandingkan dengan nilai aktual pada data *out-sample*. Sedangkan gambar 4.9 memperlihatkan peramalan dengan model ARIMA untuk 12 bulan berikutnya.



Gambar 4.9. Plot Data volume Eskpor Perikanan kelompok komoditi 302 beserta peramalan 12 bulan berikutnya

4.2.2 Pemodelan dengan FFNN

Pemodelan dengan FFNN dilakukan setelah melakukan *scaling* data, sedangkan pemilihan variabel input dilakukan berdasarkan lag *autoregressive* pada model ARIMA (1,0,1). Untuk melakukan peramalan dengan metode FFNN, digunakan variabel input volume ekspor kelompok komoditi 302 pada periode ($t-1$) atau pada periode satu bulan sebelumnya. Lapisan tersembunyi yang digunakan pada arsitektur jaringan FFNN adalah satu lapisan tersembunyi dengan kombinasi jumlah *hidden neuron* sebanyak 1 sampai dengan 10 *neuron*. Untuk mendapatkan arsitektur optimal, dilakukan pemilihan banyaknya *neuron* pada lapisan tersembunyi sebanyak 1 sampai dengan 10, dan diulangi sebanyak 5 kali percobaan hingga mendapatkan jumlah *hidden node* dengan nilai MAPE minimum. Sedangkan jumlah output yang digunakan dalam arsitektur FFNN ini adalah sebanyak 1 unit. Pada lapisan tersembunyi, digunakan fungsi aktivasi logistik *sigmoid* sedangkan pada lapisan output digunakan fungsi aktivasi *purelin* (linier). Pada tahap learning (pembelajaran) update bobot dilakukan dengan menggunakan algoritma Levenberg-Marquardt (*trainlm*). Tabel 4.6 menunjukkan bahwa nilai AIC minimum dicapai oleh *hidden node* sebanyak 3 buah pada percobaan kelima. Dengan demikian arsitektur FFNN terbaik untuk kelompok komoditi 302 adalah NN(1;3;1).

Tabel 4.6 Nilai AIC pada Masing-masing Jumlah *Hidden Node*

Jumlah Hidden Node	Percobaan 1	Percobaan 2	Percobaan 3	Percobaan 4	Percobaan 5
1	-607.584	-553.2878	-567.9701	-645.5336	-639.5654
2	-652.1006	-523.5867	-512.0507	-650.5538	-646.152
3	-630.2901	-646.1589	-648.474	-640.4005	-657.4999
4	-649.9353	-651.1916	-651.1159	-475.0645	-641.9981
5	-634.3633	-627.5683	-565.0347	-640.2031	-647.747
6	-558.4178	-640.6842	-624.8106	-629.9898	-643.3225
7	-600.4236	-635.1265	-642.3503	-589.0468	-615.2269
8	-536.732	-617.3945	-539.3149	-650.8811	-568.8854
9	-593.9167	-639.018	-460.4477	-644.5815	-616.8877
10	-620.6652	-590.3999	-583.9972	-596.9137	-642.1043

Tabel 4.7 Nilai Bobot pada model NN (1;3;1)

Bobot input <i>hidden</i>	Bobot bias <i>hidden</i>	Bobot <i>hidden</i> output	Bobot bias output
(1)	(2)	(3)	(4)
26,86	-2,6561	2,8244	1,8544
32,2378	-2,9014	-2,7445	
0,2135	1,6443	-2,7533	

Berdasarkan persamaan 2.28 dan fungsi aktivasi pada persamaan 2.29 maka model NN(1;3;1) untuk kelompok komoditi 302 ekspor perikanan secara matematis dapat ditulis sebagai berikut:

$$\hat{Y}_t = b^o + w_1^o f_1^h + w_2^o f_2^h$$

$$\hat{Y}_t = 1,85 + 2,82 f_1^h - 2,74 f_2^h - 2,75 f_3^h$$

dengan:

$$f_1^h = \frac{1}{1 + e^{-[-2,66 + 26,86 Y_{t-1}]}}$$

$$f_2^h = \frac{1}{1 + e^{-[-2,90 + 32,24 Y_{t-1}]}}$$

$$f_3^h = \frac{1}{1 + e^{-[1,64 + 0,21 Y_{t-1}]}}$$

Jika dimisalkan $\hat{Y}_{a,t}$ sebagai $\hat{Y}_{a,t(sv)}$ dimana (sv) merupakan notasi yang menunjukkan bahwa output dari FFNN masih dalam bentuk *scaled value*, maka

nilai peramalan dengan metode FFNN berdasarkan persamaan (2.28) secara matematis dapat ditulis sebagai berikut:

$$\hat{Y}_{a,t(0)} = \hat{Y}_{a,t(sv)} \cdot (\max(Y) - \min(Y)) + \min(Y)$$

dimana $\max(Y)$ merupakan nilai maksimum dari deret waktu, dan $\min(Y)$ merupakan nilai minimum dari deret waktu, dan $\hat{Y}_{a,t(0)}$ merupakan nilai peramalan setelah melalui *postprocessing*. Dengan demikian model FFNN dapat ditulis sebagai berikut:

$$\hat{Y}_{a,t(0)} = 14.294.511 \hat{Y}_{a,t(sv)} + 4.286.619$$

4.2.3 Pemodelan dengan Hibrida ARIMA-NN

Pemodelan dengan Hibrida ARIMA-NN dilakukan dengan menjadikan residual pada ARIMA sebagai input, dimana pemilihan variabel input juga berdasarkan lag *autoregressive* yang telah melalui proses *scaling*. Dengan kombinasi jumlah *hidden neuron* sebanyak 1 s.d 10 dan diulangi sebanyak 5 kali percobaan diperoleh hasil seperti dalam tabel berikut ini:

Tabel 4.8 Nilai AIC pada Masing-masing Jumlah *Hidden Node*

H	Percobaan 1	Percobaan 2	Percobaan 3	Percobaan 4	Percobaan 5
1	-594.9	-599.4	-594.7	-592.2	-595.8
2	-587.2	-599.1	-586.8	-586	-586.9
3	-591	-581.4	-586	-587.9	-584.9
4	-574.3	-580.1	-585.6	-574.4	-583.7
5	-567.8	-568.5	-577.7	-576.8	-574.9
6	-561.8	-566.1	-565.5	-571	-569.7
7	-562.6	-562.3	-568.8	-555.8	-559.3
8	-550.1	-556.2	-557.7	-558.5	-549.8
9	-550.7	-550.6	-546.4	-553.1	-554.3
10	-537.9	-542.1	-542.5	-544.5	-539.1

Berdasarkan tabel 4.8, nilai AIC digunakan sebagai kriteria kenbaikan model pada data *training* untuk mendapatkan model terbaik. Adapun nilai minimum AIC dicapai pada kombinasi 1 unit node pada lapisan tersembunyi pada percobaan ke-2. Dengan demikian model Hibrida ARIMA-NN yang terbentuk dengan 1 unit variabel input (t-1) adalah NN(1;1;1). Rincian bobot pada lapisan tersembunyi dan output dirincikan dalam tabel berikut:

Tabel 4.9 Nilai Bobot pada Model NN(1;1;1)

Bobot input <i>hidden</i>	Bobot bias <i>hidden</i>	Bobot <i>hidden</i> output	Bobot bias output
2,8	0	13,4534	18,6386

Berdasarkan tabel 4.9 diatas, model arsitektur NN(1;1;1) untuk peramalan residual ARIMA dari volume ekspor perikanan untuk kelompok komoditi 302 dapat ditulis secara matematis sebagai berikut:

$$\hat{\varepsilon}_{a,t} = 18,64 + 13,45f_1^h$$

dengan:

$$f_1^h = \frac{1}{1 + e^{-[2,8 \hat{\varepsilon}_{a,t-1}]}}$$

Untuk keperluan *postprocessing*, residual ARIMA dikembalikan ke ukuran nilai sebenarnya dan digunakan nilai minimum residual ARIMA yaitu -0,00015 dan nilai maksimum residual yaitu 0,0001 sehingga model matematisnya adalah sebagai berikut:

$$\hat{\varepsilon}_{a,t(0)} = 0,0002 \hat{\varepsilon}_{a,t(sv)} + 0,00015$$

Setelah menggabungkan model ARIMA (1,0,1) dengan model FFNN, maka model hibrida ARIMA-NN untuk volume ekspor perikanan pada kelompok komoditi 302 secara matematis dapat ditulis sebagai berikut:

$$\hat{Y}_t = \hat{Y}_{L,t} + \hat{Y}_{N,t}$$

dengan $\hat{Y}_{L,t} = 0,0004 + 0,94Y_{t-1} - 0,74e_{t-1} + e_t$

dan $\hat{Y}_{N,t} = 0,0002 \hat{\varepsilon}_{a,t(sv)} + 0,00015$

Dimana $\hat{\varepsilon}_{a,t(sv)}$ merupakan output residual ARIMA dalam bentuk *scaled value* dari metode FFNN.

4.2.4 Pemodelan dengan WFTS

Pemodelan dengan WFTS dilakukan dengan beberapa algoritma, yakni algoritma Chen, Yu, Lee, dan Cheng. Langkah pertama yang dilakukan pada

keempat algoritma tersebut adalah mendefinisikan himpunan semesta ke dalam beberapa himpunan bagian. Miller (1956) dalam Cheng (2008) mengemukakan suatu usulan untuk membagi data ke dalam tujuh himpunan linguistik (lihat tabel 4.10) Selanjutnya, jika terdapat nilai data yang lebih besar daripada nilai rata-rata dari masing-masing himpunan awal tersebut, maka dapat dilakukan partisi pada himpunan-himpunan tersebut. Pada kelompok komoditi 302, setelah dibentuk tujuh himpunan awal, terdapat beberapa himpunan dimana anggota himpunannya lebih besar dibandingkan jumlah rata-rata anggota himpunan sehingga perlu dilakukan partisi. Pembentukan himpunan linguistik setelah dilakukan partisi dapat dilihat pada tabel 4.11.

Tabel 4.10 Pembentukan Himpunan Linguistik Awal pada Kelompok Komoditi 302

Himpunan	Batas Bawah	Batas Atas	Mean	Jarak Interval
U1	4000	6100	5,524	2100
U2	6100	8200	7,227	2100
U3	8200	10300	8,935	2100
U4	10300	12400	11,224	2100
U5	12400	14500	12,868	2100
U6	14500	16600	15,860	2100
U7	16600	18700	17,472	2100

Tabel 4. 11 Pembentukan Himpunan Linguistik setelah Dilakukan Partisi pada Kelompok Komoditi 302

Himpunan	Batas Bawah	Batas Atas	Jarak Interval	Mid point
U1	4,000	5,000	1,000	4500
U2	5,000	6,000	1,000	5500
U3	6,000	7,000	1,000	6500
U4	7,000	8,000	1,000	7500
U5	8,000	10,100	2,100	9050
U6	10,100	12,200	2,100	11150
U7	12,200	14,300	2,100	13250
U8	14,300	16,400	2,100	15350
U9	16,400	18,500	2,100	17450
U10	18,500	20,600	2,100	19550

Setelah mendefinisikan himpunan sampel, langkah kedua yang dilakukan adalah mendefinisikan himpunan *fuzzy* A_i dari himpunan semesta berdasarkan interval partisi yang dibuat, sebagai berikut:

Tabel 4. 12 Himpunan *Fuzzy* untuk 10 variabel linguistik

$$\begin{aligned}
 A_1 &= 1/u_1 + 0,5/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} \\
 A_2 &= 0,5/u_1 + 1/u_2 + 0,5/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} \\
 A_3 &= 0/u_1 + 0,5/u_2 + 1/u_3 + 0,5/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} \\
 A_4 &= 0/u_1 + 0/u_2 + 0,5/u_3 + 1/u_4 + 0,5/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} \\
 A_5 &= 0/u_1 + 0/u_2 + 0/u_3 + 0,5/u_4 + 1/u_5 + 0,5/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} \\
 A_6 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0,5/u_5 + 1/u_6 + 0,5/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} \\
 A_7 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0,5/u_6 + 1/u_7 + 0,5/u_8 + 0/u_9 + 0/u_{10} \\
 A_8 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0,5/u_7 + 1/u_8 + 0,5/u_9 + 0/u_{10} \\
 A_9 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0,5/u_8 + 1/u_9 + 0,5/u_{10} \\
 A_{10} &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0,5/u_9 + 1/u_{10}
 \end{aligned}$$

Tabel 4. 13 Nilai linguistik pada data kelompok komoditi 302

Tahun	Bulan	Volume Ekspor (ton)	Nilai Linguistik
1999	Jan	7,054	A4
	Feb	6,526	A3
	Mar	15,860	A8
	Apr	9,301	A5
⋮	⋮	⋮	⋮
2015	Apr	6,079	A3
	May	5,906	A2
	Jun	5,476	A2
	Jul	4,610	A1

Tabel 4.13 menyajikan nilai linguistik pada keseluruhan data volume ekspor perikanan pada kelompok komoditi 302. Langkah selanjutnya yang dilakukan adalah menentukan *Fuzzy Logical Relationship* (FLR). Tabel 4.14 menyajikan hasil dari pembentukan FLR pada data kelompok komoditi 302.

Tabel 4.14 Pembentukan FLR pada kelompok komoditi 302

Tahun	Bulan	Data Aktual (Yt)	<i>Fuzzy Logical Relationship</i>	
			LHS	RHS
1999	Jan	7,054		
	Feb	6,526	A4	A3
	Mar	15,860	A3	A8
	Apr	9,301	A8	A5
⋮	⋮	⋮	⋮	⋮
2015	Apr	6,079	A2	A3
	May	5,906	A3	A2
	Jun	5,476	A2	A2
	Jul	4,610	A2	A1

4.2.4.1 Peramalan dengan Algoritma Chen (1)

Pembentukan bobot untuk peramalan pada A_i dengan algoritma Chen(1) disajikan dalam tabel 4.17 untuk A_1 .

Tabel 4.17 Pembentukan bobot untuk peramalan pada A_1

Urutan	LHS atau Y_t	RHS atau Y_{t+1}	mid-point dari RHS
1	A1	A2	m_2
2	A1	A2	m_2
3	A1	A2	m_2
4	A1	A4	m_4

Asumsikan bahwa $Y_t = A_1$ maka nilai peramalan pada waktu $t + 1$ adalah:

$$\hat{Y}_{t+1} = \frac{m_2 + m_4}{2} = \frac{1}{2} m_2 + \frac{1}{2} m_4$$

Langkah yang serupa juga dilakukan untuk mendapatkan nilai peramalan pada waktu $t + 1$ untuk $Y_t = A_2$ sampai dengan $Y_t = A_{10}$.

4.2.4.2 Peramalan dengan Algoritma Chen (2)

Merujuk pada tabel 4.17, peramalan dengan algoritma Chen(2) adalah sebagai berikut:

Asumsikan bahwa $Y_t = A_1$ maka nilai peramalan pada waktu $t + 1$ adalah:

$$\hat{Y}_{t+1} = \frac{m_2 + m_2 + m_2 + m_4}{4} = \frac{3}{4} m_2 + \frac{1}{4} m_4$$

4.2.4.3 Peramalan dengan Algoritma Yu

Merujuk pada tabel 4.17, peramalan dengan algoritma Yu adalah sebagai berikut:

Asumsikan bahwa $Y_t = A_1$ maka nilai peramalan pada waktu $t + 1$ adalah:

$$\hat{Y}_{t+1} = \frac{1m_2 + 2m_2 + 3m_2 + 4m_4}{1 + 2 + 3 + 4} = \frac{1}{10} m_2 + \frac{2}{10} m_2 + \frac{3}{10} m_2 + \frac{4}{10} m_4$$

4.2.4.4 Peramalan dengan Algoritma Lee

Merujuk pada tabel 4.17, peramalan dengan algoritma Lee ($c = 1,6$) adalah sebagai berikut:

Asumsikan bahwa $Y_t = A_1$ maka nilai peramalan pada waktu $t + 1$ adalah:

$$\hat{Y}_{t+1} = \frac{1m_2 + 1,6m_2 + 2,56m_2 + 4,096m_4}{1 + 1,6 + 2,56 + 4,096} = \frac{1}{9,256} m_2 + \frac{1,6}{9,256} m_2 + \frac{2,56}{9,256} m_2 + \frac{4,096}{9,256} m_4$$

4.2.4.5 Peramalan dengan Algoritma Cheng

Merujuk pada tabel 4.17, peramalan dengan algoritma Lee adalah sebagai berikut:

Asumsikan bahwa $Y_t = A_1$ maka nilai peramalan pada waktu $t + 1$ adalah:

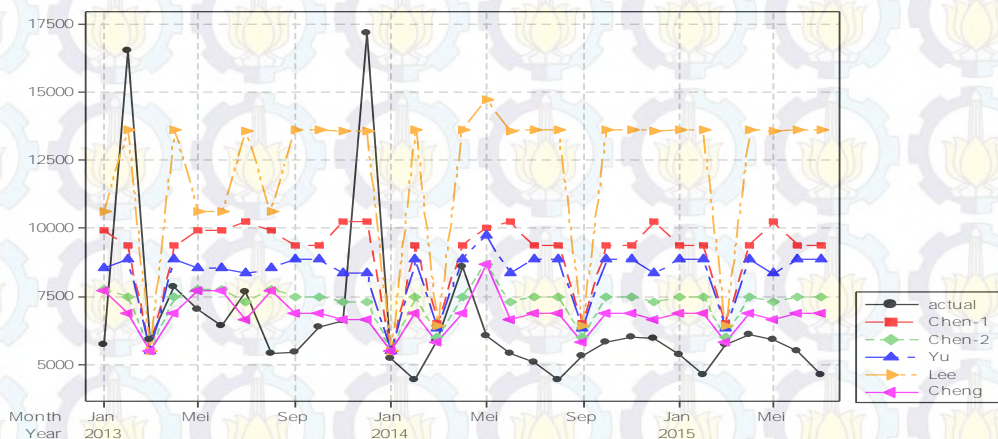
$$\hat{Y}_{t+1} = \frac{1m_2 + 2m_2 + 3m_2 + 1m_4}{1 + 2 + 3 + 1} = \frac{1}{7} m_2 + \frac{2}{7} m_2 + \frac{3}{7} m_2 + \frac{1}{7} m_4$$

Selanjutnya dilakukan peramalan WFTS menurut algoritma Chen, Yu, Lee, dan Cheng untuk keseluruhan nilai data pada kelompok komoditi 302. Tabel 4.18 menyajikan kinerja peramalan menurut masing-masing algoritma. Merujuk pada tabel 4.18, dari keempat algoritma WFTS yang dilakukan, metode WFTS dengan algoritma Cheng menunjukkan kinerja terbaik dengan nilai MAPE minimum yakni sebesar 26,34.

Tabel 4.18 Kinerja Peramalan WFTS pada Kelompok Komoditi 302

Metode WFTS	RMSE	MAPE
Chen-1	3.866	56,9263
Chen-2	2.956	30,0171
Yu-1	3.398	44,7697
Lee	5.812	75,9006
Cheng	3.219	26,3370


Secara visual, hasil peramalan metode WFTS menurut algoritma dibandingkan dengan nilai aktual sebagai berikut:



Gambar 4.10 Perbandingan Hasil Peramalan WFTS pada Kelompok Komoditi 302

Melalui gambar 4.10 diatas, terlihat bahwa hasil peramalan WFTS dengan algoritma Chen-2, Yu, dan Cheng memiliki pola yang menyerupai pola data aktual. Sedangkan hasil peramalan menurut algoritma Lee tampak berbeda jauh dengan pola data aktual. Hal ini didukung dengan nilai MAPE yang terbesar (lihat tabel 4.12) yang menunjukkan kinerja peramalan yang kurang memuaskan pada kelompok komoditi 302.

4.2.5 Perbandingan Hasil Peramalan pada Kelompok Komoditi 302



Gambar 4.11 Perbandingan Hasil Peramalan pada Kelompok Komoditi 302


Melalui gambar 4.11 terlihat bahwa plot peramalan yang paling mendekati nilai aktual adalah peramalan dengan metode WFTS dengan algoritma Cheng.

4.3 Kelompok Komoditi 303

4.3.1 Pemodelan dengan Metode ARIMA

Pada bagian ini disajikan bagaimana memperoleh model ARIMA terbaik menurut prosedur Box-Jenkins.


1. Plot data *training* Januari 1999 s.d Desember 2012



Gambar 4.12 Plot Data *Training* Volume Ekspor Perikanan Kelompok Komoditi 303


Gambar 4.12 secara visual memperlihatkan pola data *training* untuk kelompok komoditi 303 tanpa adanya tren. Namun jelas terlihat adanya sejumlah *outlier* pada sejumlah waktu tertentu diantaranya adalah pada November 2004 dan Mei 2006.

a. Transformasi Box-Cox dan Uji Unit Root ADF



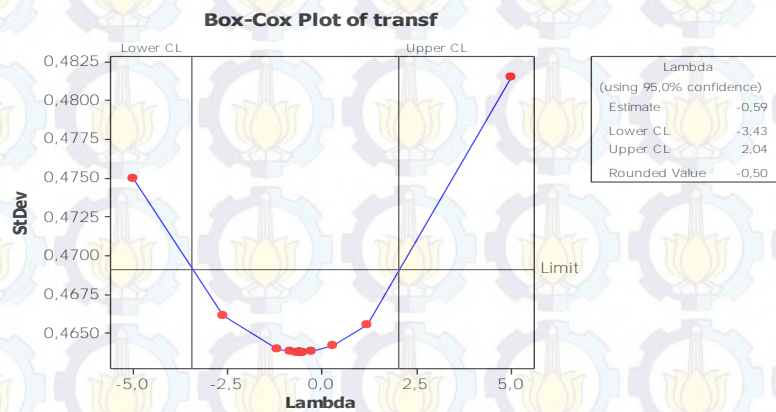
Gambar 4.13 Box-Cox Plot untuk Kelompok Komoditi 303

Hasil transformasi Box-Cox menunjukkan nilai lambda sebesar 0,00 sehingga perlu dilakukan transformasi ln (logaritma natural) agar asumsi stasioneritas pada varians terpenuhi.



Gambar 4.14 Plot data *training* setelah transformasi ln

Gambar 4.14 menunjukkan plot data *training* setelah dilakukan transformasi ln ternyata menunjukkan pola data yang belum stasioner dalam varians sehingga perlu dilakukan transformasi sekali lagi.




Gambar 4.15 Box Cox plot setelah transformasi ln

Gambar 4.15 menunjukkan nilai lambda sebesar -0,5 yang berarti perlu dilakukannya transformasi satu per akar kuadrat atas data *training* untuk kelompok komoditi 303 untuk mencapai stasioneritas data. Selanjutnya melalui uji ADF (tabel 4.19), diperoleh hasil bahwa pola data telah stasioner pada level sehingga tidak perlu dilakukan *differencing*, atau dengan kata lain data telah memenuhi asumsi stasioneritas pada mean.

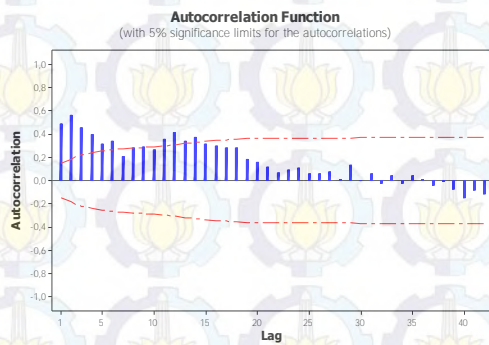
Tabel 4.19 Hasil Uji Augmented Dickey-Fuller pada Kelompok Komoditi 303

Parameter	Estimasi	Std Error	τ_{hitung}	$\tau_{tabel (5\%)}$	Keputusan
δ	-0,283583	0,071420	-3,970639	-2,878937	Tolak H_0

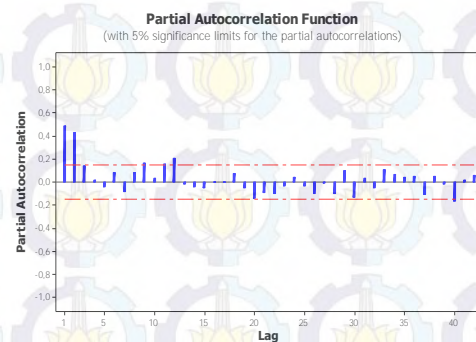
b. Plot data *training*, ACF, dan PACF setelah transformasi



(a) plot hasil transformasi



(b) Plot ACF



(c) Plot PACF

Gambar 4.16 Plot data *training*, ACF, dan PACF Kelompok Komoditi 303 setelah transformasi

Melalui gambar 4.16 terlihat plot data setelah dilakukan transformasi dan *differencing* telah stasioner. Plot ACF menunjukkan adanya pola *dies down* sedangkan plot PACF memperlihatkan pola *cuts off* setelah lag 2 dan nilai autokorelasi melewati batas lagi pada lag 12.

c. Estimasi Parameter dan *Diagnostic Check*

Hasil estimasi parameter yang dilanjutkan dengan cek diagnosa pada sejumlah dugaan model ARIMA menghasilkan model terbaik ARIMA $(2,0,0)(0,0,1)^{12}$ sebagai berikut:

Tabel 4.20. Estimasi Parameter dan Uji Signifikansi Parameter Model ARIMA $(2,0,0)(0,0,1)^{12}$

Parameter	estimasi	p-Value	keputusan
MU	0.24503	<.0001	signifikan
MA1,1	-0.20735	0.0079	signifikan
AR1,1	0.23638	0.0009	signifikan
AR1,2	0.42755	<.0001	signifikan

Hasil uji signifikansi parameter menunjukkan bahwa model signifikan dengan nilai p-value kurang dari 0,05. Selanjutnya untuk mengetahui apakah model telah memenuhi asumsi *white noise*, dilakukan uji L-Jung box atau uji chi-square terhadap residual. Berdasarkan tabel, model ARIMA $(2,0,0)(0,0,1)^{12}$ telah memenuhi asumsi *white noise* pada semua lag yang ditunjukkan dengan nilai p-value yang lebih besar dari 0,05.

Tabel 4.21 L-Jung Box untuk Residual ARIMA $(2,0,0)(0,0,1)^{12}$

Lag	Chi-Square	DF	p-value
6	4.93	3	0.1772
12	14.58	9	0.1032
18	24.71	15	0.0539
24	27.66	21	0.1501
30	34.56	27	0.1503

Tabel 4.22 Uji Distribusi Normal untuk ARIMA $(2,0,0)(0,0,1)^{12}$

Test	Statistik Uji	p-value	keputusan	
Shapiro-Wilk	W	0.970768	0.0013	tidak normal
Kolmogorov-Smirnov	D	0.075454	0.0199	tidak normal
Cramer-von Mises	W-Sq	0.221822	<0.0050	tidak normal
Anderson-Darling	A-Sq	1.37694	<0.0050	tidak normal

Tabel 4.22 memperlihatkan uji terhadap normalitas dari model ARIMA (2,0,0)(0,0,1)¹² yang menunjukkan nilai p-value dari Kolmogorv-Smirnov sebesar 0,0199 (kurang dari 0,05) yang berarti residual untuk model ARIMA (2,0,0)(0,0,1)¹² belum berdistribusi normal. Hal ini dapat diakibatkan oleh pengaruh dari adanya sejumlah *outlier* (lihat gambar 4.12). sejumlah *outlier* yang terdeteksi terdapat pada data dan jenis dari *outlier-outlier* tersebut dapat dilihat pada tabel berikut.

Tabel 4.23 Ringkasan Deteksi *Outlier* menurut Uji Chi-Square pada ARIMA (2,0,0)(0,0,1)¹²

No Observasi	Tipe <i>Outlier</i>	Estimasi	Chi-Square	p-value
89	Additive	-0.01507	23.54	<.0001
42	Additive	-0.01399	20.78	<.0001
60	Additive	-0.00987	10.38	0.0013
62	Additive	-0.01318	18.86	<.0001
55	Additive	0.0097767	12.35	0.0004
120	Additive	-0.0096629	11.68	0.0006
71	Additive	-0.0091149	11.14	0.0008
130	Shift	-0.0047655	11.36	0.0008
14	Additive	0.0080158	9.76	0.0018
2	Additive	0.0099457	12.59	0.0004

Oleh karena itu, untuk mendapatkan suatu model yang memenuhi asumsi normalitas, uji signifikansi parameter dan cek diagnosa diulangi sekali lagi dengan memperhitungkan adanya *outlier* pada model. Proses pemilihan *outlier* yang dimasukkan ke dalam model dilakukan satu per satu berdasarkan pengamatan pada plot data. Pada akhirnya, outlier yang dimasukkan ke dalam model adalah sebanyak 4 (empat) buah *outlier*, yakni *additive outlier* pada waktu ke 89, 71, 60, dan 55. Tabel 4.24 memperlihatkan bahwa parameter yang diuji pada model ARIMA (2,0,0)(0,0,1)¹² setelah memperhitungkan sebanyak 4 (empat) buah *outlier* telah signifikan.

Tabel 4.24 Estimasi Parameter dan Uji Signifikansi Parameter Model ARIMA (2,0,0)(0,0,1)¹² dengan deteksi *outlier*

Parameter	Estimasi	p-value	Keputusan
MU	0.24513	<.0001	signifikan
MA1,1	-0.28241	0.0003	signifikan
AR1,1	0.33833	<.0001	signifikan
AR1,2	0.35728	<.0001	signifikan
NUM1	-0.0161	<.0001	signifikan
NUM2	-0.0086895	0.0144	signifikan
NUM3	-0.01191	0.0008	signifikan
NUM4	0.0093885	0.0081	signifikan

Tabel 4.25 L-Jung Box untuk Pengujian Residual ARIMA (2,0,0)(0,0,1)¹² dengan deteksi *outlier*

Lag	Chi-Square	DF	p-value	Kesimpulan
6	4.93	3	0.1772	<i>White noise</i>
12	14.58	9	0.1302	<i>White noise</i>
18	24.71	15	0.0539	<i>White noise</i>
24	27.66	21	0.1501	<i>White noise</i>
30	34.56	27	0.1503	<i>White noise</i>

Hasil uji *chi-square* dari residual pada L-Jung Box setelah memperhitungkan adanya *outlier* pada model menunjukkan bahwa model sudah memenuhi asumsi *white noise* pada semua lag dengan nilai p-value lebih besar dari 0,05. Selanjutnya pengujian normalitas setelah memperhitungkan adanya *outlier* dapat dilihat pada tabel 4.26.

Tabel 4.26 Pengujian Distribusi Normal untuk ARIMA (2,0,0)(0,0,1)¹² dengan deteksi *outlier*

Uji	Chi-Square	p-value	Kesimpulan
Kolmogorov-Smirnov	0.06	>0,115	berdistribusi normal

Melalui tabel 4.26 terlihat bahwa nilai *p-value* untuk uji Kolmogorov-Smirnov bernilai lebih dari 0,15 yang berarti juga lebih besar dari 0,05, sehingga disimpulkan bahwa residual sudah berdistribusi normal. Dengan demikian model ARIMA (2,0,0)(0,0,1)¹² dengan 4 (empat) buah *outlier* merupakan model terbaik untuk volume ekspor perikanan pada kelompok komoditi 303. Berdasarkan model

umum ARIMA (p,d,q) dengan deteksi *outlier* secara matematis adalah sebagai berikut:

$$Z_t = \theta_0 + \omega I_t^{(T)} + \frac{\theta^{(B)}}{\phi^{(B)}} e_t$$

Dengan memasukkan sebanyak 4(empat) buah *outlier*, maka persamaan tersebut akan menjadi:


$$Z_t = \theta_0 + \omega_1 I_t^{(89)} + \omega_2 I_t^{(71)} + \omega_3 I_t^{(60)} + \omega_4 I_t^{(55)} + \frac{(1-\theta_{12}B^{12})}{(1-\phi_1B-\phi_2B^2)} e_t$$

Selanjutnya, masukkan nilai estimasi parameter yang telah diperoleh ke dalam persamaan, sehingga model ARIMA (2,0,0)(0,0,1)¹² dengan 4 (empat) *outlier* untuk kelompok komoditi 303 adalah sebagai berikut:

$$\hat{Z}_t = 0,25 - 0,02I_{A,t}^{(89)} - 0,01I_{A,t}^{(71)} - 0,01I_{A,t}^{(60)} + 0,01I_{A,t}^{(55)} + \frac{(1 + 0,28Z_{t-12})}{(1 - 0,34Z_{t-1} - 0,36Z_{t-2})} e_t$$


d. Peramalan dengan model ARIMA terbaik

Setelah persamaan model ARIMA (2,0,0)(0,0,1)¹² diperoleh melalui data *in-sample*, selanjutnya dilakukan peramalan pada data *out-sample* dan peramalan 12 bulan ke depan dari data pada bulan terakhir. Gambar 4.17 memperlihatkan secara visual perbandingan hasil ramalan ARIMA (2,0,0)(0,0,1)¹² dengan nilai aktual.



Gambar 4.17 Perbandingan Hasil Ramalan dengan nilai Aktual pada outsample untuk kelompok komoditi 303

Sedangkan peramalan untuk 12 bulan ke depan secara visual dapat dilihat pada gambar berikut ini:



Gambar 4.18 Peramalan 12 bulan berikutnya dari kelompok komoditi 303

Melalui gambar 4.18, terlihat bahwa peramalan 12 bulan ke depan mengalami peningkatan yang cukup signifikan. Hal ini dapat terjadi akibat proses transformasi logaritma natural (\ln) yang dilakukan terhadap data kelompok komoditi 303.

4.3.2 Pemodelan dengan FFNN

Pemodelan dengan FFNN dilakukan setelah melakukan *scaling* data, atau *pre-processing*, sedangkan pemilihan variabel input dilakukan berdasarkan lag *autoregressive* pada model ARIMA (2,0,0)(0,0,1)¹². Untuk melakukan peramalan dengan metode FFNN, digunakan variabel input volume ekspor kelompok komoditi 303 pada periode (t-1) dan (t-2) atau pada periode satu bulan dan bulan sebelumnya. Lapisan tersembunyi yang digunakan pada arsitektur jaringan FFNN adalah satu lapisan tersembunyi dengan kombinasi jumlah *hidden neuron* sebanyak 1 sampai dengan 10 *neuron*. Untuk mendapatkan arsitektur optimal, dilakukan pemilihan banyaknya *neuron* pada lapisan tersembunyi sebanyak 1 sampai dengan 10, dan diulangi sebanyak 5 kali percobaan hingga mendapatkan jumlah *hidden node* dengan nilai AIC minimum. Sedangkan jumlah output yang digunakan dalam arsitektur FFNN ini adalah sebanyak 1 unit. Pada lapisan tersembunyi, digunakan fungsi aktivasi logsig sedangkan pada lapisan output digunakan fungsi aktivasi purelin (linier). Pada tahap *learning* (pembelajaran)

update bobot dilakukan dengan menggunakan algoritma Levenberg-Marquardt (*trainlm*).

Tabel 4.27 menyajikan kriteria kebaikan model yang digunakan untuk mendapatkan arsitektur NN yang terbaik pada data *in-sample* adalah nilai AIC. Selanjutnya, kriteria kebaikan model yang digunakan pada data *out-sample*, setelah mendapatkan arsitektur NN terbaik, adalah nilai RMSE dan MAPE. Tabel 4.27 menunjukkan bahwa nilai AIC minimum dicapai oleh kombinasi *hidden node* sebanyak 4 buah pada percobaan kedua. Dengan demikian arsitektur FFNN terbaik untuk model ARIMA (2,0,0)(0,0,1)¹² pada kelompok komoditi 303 adalah NN(2:4;1).

Tabel 4.27 Nilai AIC pada Masing-masing Jumlah *Hidden Node*

Jumlah Hidden Node	Percobaan 1	Percobaan 2	Percobaan 3	Percobaan 4	Percobaan 5
1	-678.393	-678.4238	-677.4627	-677.4617	-678.4026
2	-673.8851	-669.3546	-670.2341	-648.0108	-674.8018
3	-664.4807	-656.5056	-670.1449	-666.9514	-681.7189
4	-663.9153	-702.3292	-661.0072	-694.137	-659.0426
5	-657.7101	-698.909	-647.9758	-696.9648	-659.7805
6	-641.1734	-650.9024	-652.0227	-688.7331	-641.7746
7	-628.1421	-637.6833	-681.2094	-631.2989	-632.6636
8	-672.1392	-671.9853	-660.6841	-672.051	-666.8638
9	-665.4554	-669.1208	-660.6581	-669.7179	-664.0691
10	-607.5405	-649.2674	-667.9547	-594.8881	-637.6488

Tabel 4.28 Nilai bobot pada Masing-masing Jumlah *Hidden Node*

Bobot input <i>hidden</i>	Bobot bias <i>hidden</i>	Bobot <i>hidden</i> output	Bobot bias output
-0,1307	-0,1175	-0,7161	-6,0514
22,3441	-30,9687	-23,4422	4,7589
-0,6851	-0,5926	0,2051	1,1283
20,1779	-28,5151	-21,785	-4,7948

Berdasarkan persamaan 2.28 dan fungsi aktivasi pada persamaan 2.29 maka model NN(2;4;1) untuk kelompok komoditi 303 ekspor perikanan secara matematis dapat ditulis sebagai berikut:

$$\hat{Y}_t = b^o + w_1^o f_1^h + w_2^o f_2^h + w_3^o f_3^h + w_4^o f_4^h$$

$$\hat{Y}_t = 1,41 - 6,05f_1^h + 4,76f_2^h + 1,13f_3^h - 4,79f_4^h$$

dengan:

$$f_1^h = \frac{1}{1 + e^{-[-0,72 - 0,13Y_{t-1} - 0,12Y_{t-2}]}}$$

$$f_2^h = \frac{1}{1 + e^{-[-23,44 + 22,34Y_{t-1} - 30,97Y_{t-2}]}}$$

$$f_3^h = \frac{1}{1 + e^{-[0,21 - 0,69Y_{t-1} - 0,59Y_{t-2}]}}$$

$$f_4^h = \frac{1}{1 + e^{-[-21,79 + 20,18Y_{t-1} - 28,51Y_{t-2}]}}$$

Jika dimisalkan $\hat{Y}_{a,t}$ sebagai $\hat{Y}_{a,t(sv)}$ dimana (sv) merupakan notasi yang menunjukkan bahwa output dari FFNN masih dalam bentuk *scaled value*, maka nilai peramalan dengan metode FFNN berdasarkan persamaan (2.28) secara matematis dapat ditulis sebagai berikut:

$$\hat{Y}_{a,t(0)} = \hat{Y}_{a,t(sv)} \cdot (\max(Y) - \min(Y) + \min(Y))$$

dimana max (Y) merupakan nilai maksimum dari deret waktu, dan min (Y) merupakan nilai minimum dari deret waktu, dan $\hat{Y}_{a,t(0)}$ merupakan nilai peramalan setelah melalui *postprocessing*. Dengan demikian model FFNN dapat ditulis sebagai berikut:

$$\hat{Y}_{a,t(0)} = 151.850.891 \hat{Y}_{a,t(sv)} + 2.571.709$$

4.3.3 Pemodelan dengan Hibrida ARIMA-NN

Pemodelan dengan Hibrida ARIMA-NN dilakukan dengan menjadikan residual pada ARIMA sebagai input., dimana pemilihan variabel input juga berdasarkan lag *autoregressive* yang telah melalui proses *scaling*. Dengan

kombinasi jumlah *hidden neuron* sebanyak 1 s.d 10 dan diulangi sebanyak 5 kali percobaan diperoleh hasil seperti dalam tabel berikut ini:

Tabel 4.29 Nilai MAPE pada Masing-masing Jumlah *Hidden Node*

Jumlah node	Percobaan 1	Percobaan 2	Percobaan 3	Percobaan 4	Percobaan 5
1	0.5125	0.5259	0.5076	0.5169	0.5146
2	0.5077	0.5098	0.5264	0.5039	0.5453
3	0.6427	0.5047	0.5099	0.5334	0.5108
4	0.5275	0.5423	0.519	0.5082	0.5483
5	0.541	0.5561	0.6571	0.5209	0.6124
6	0.6144	0.515	0.5065	0.6407	0.5107
7	1.6471	0.6569	0.6379	0.5113	0.6454
8	0.7775	0.5838	0.6209	0.538	0.5101
9	0.5301	0.5103	0.526	0.5955	0.6081
10	0.5177	0.5049	0.5088	0.6133	0.5209

Berdasarkan tabel diatas, nilai minimum MAPE dicapai pada kombinasi 2 unit node pada lapisan tersembunyi pada percobaan ke-4. Dengan demikian model Hibrida ARIMA-NN yang terbentuk dengan 2 unit variabel input (t-1) dan (t-2) adalah NN(2;2;1). Rincian bobot pada lapisan tersembunyi dan output dirincikan dalam tabel berikut:

Tabel 4.30 Nilai bobot pada Masing-masing Jumlah *Hidden Node*

Bobot input <i>hidden</i>	Bobot bias <i>hidden</i>	Bobot <i>hidden</i> output	Bobot bias output
2,0563	-3,8515	0,7926	0,8393
-3,4254	-3,9571	0,2192	
-3,4516			
-1,9423			

Berdasarkan tabel 4.30 diatas, model arsitektur NN(2;2;1) untuk peramalan residual ARIMA dari volume ekspor perikanan untuk kelompok komoditi 303 dapat ditulis secara matematis sebagai berikut:

$$\hat{\varepsilon}_{a,t} = 0,84 + 0,79f_1^h + 0,22f_2^h$$

dengan:

$$f_1^h = \frac{1}{1 + e^{-[-3,85 + 2,06 \hat{\varepsilon}_{a,t-1} - 3,43 \hat{\varepsilon}_{a,t-2}]}}$$

$$f_2^h = \frac{1}{1 + e^{-[-3,96 - 3,45 \hat{\varepsilon}_{a,t-1} - 1,94 \hat{\varepsilon}_{a,t-2}]}}$$

Untuk keperluan *postprocessing*, residual ARIMA dikembalikan ke ukuran nilai sebenarnya dan digunakan nilai minimum residual ARIMA yaitu -1,8528 dan nilai maksimum residual yaitu 1,7291 sehingga model matematisnya adalah sebagai berikut:

$$\hat{\varepsilon}_{a,t(0)} = 3,58 \hat{\varepsilon}_{a,t(sv)} - 1,85$$

Setelah menggabungkan model ARIMA (2,0,0)(0,0,1)¹² dengan model FFNN, maka model hibrida ARIMA-NN untuk volume ekspor perikanan pada kelompok komoditi 303 secara matematis dapat ditulis sebagai berikut:

$$\hat{Z}_t = \hat{Z}_{L,t} + \hat{Z}_{N,t}$$

dengan

$$\hat{Z}_{L,t} = 0,25 - 0,02I_{A,t}^{(89)} - 0,01I_{A,t}^{(71)} - 0,01I_{A,t}^{(60)} + 0,01I_{A,t}^{(55)} + \frac{(1 + 0,28Z_{t-12})}{(1 - 0,34Z_{t-1} - 0,36Z_{t-2})} e_t$$

$$\text{dan } \hat{Z}_{N,t} = 3,58 \hat{\varepsilon}_{a,t(sv)} - 1,85$$

Dimana $\hat{\varepsilon}_{a,t(sv)}$ merupakan output residual ARIMA dalam bentuk *scaled value* dari metode FFNN.

4.3.4. Pemodelan dengan WFTS

Pemodelan dengan WFTS dilakukan dengan beberapa algoritma, yakni algoritma Chen, Yu, Lee, dan Cheng. Pada kelompok komoditi 303, setelah dibentuk tujuh himpunan awal, terdapat beberapa himpunan dimana jumlah datanya lebih besar dibandingkan jumlah rata-rata per himpunan sehingga perlu

dilakukan partisi. Tabel 4.32 menyajikan pembentukan himpunan linguistik setelah dilakukan partisi hingga menjadi 10 (sepuluh) himpunan dan penentuan nilai *mid point* dari masing-masing himpunan linguistik tersebut.

Tabel 4.31 Pembentukan Himpunan Linguistik Awal pada Kelompok Komoditi 303

Himpunan	Batas Bawah	Batas Atas	Mean	Jarak Interval
A1	2500	24500	13,269	22000
A2	24500	46500	33,796	22000
A3	46500	68500	56,556	22000
A4	68500	90500	88,711	22000
A5	90500	112500	95,805	22000
A6	112500	134500	147,296	22000
A7	134500	156500	154,423	22000

Tabel 4.32 Pembentukan Himpunan Linguistik setelah Dilakukan Partisi pada Kelompok Komoditi 303

Himpunan	Batas Bawah	Batas Atas	Jarak Interval	Mid Point
A1	2,500	13,750	11,250	8,125
A2	13,750	25,000	11,250	19,375
A3	25,000	36,250	11,250	30,625
A4	36,250	47,500	11,250	41,875
A5	47,500	58,750	11,250	53,125
A6	58,750	70,000	11,250	64,375
A7	70,000	92,500	22,500	81,250
A8	92,500	115,000	22,500	103,750
A9	115,000	137,500	22,500	126,250
A10	137,500	160,000	22,500	148,750

Tabel 4.33 menyajikan nilai linguistik pada keseluruhan data volume ekspor perikanan pada kelompok komoditi 303. Langkah selanjutnya yang dilakukan adalah menentukan *Fuzzy Logical Relationship* (FLR). Tabel 4.34 menyajikan hasil dari pembentukan FLR pada data kelompok komoditi 303.

Tabel 4. 33 Nilai linguistik pada data kelompok komoditi 303

Tahun	Bulan	Volume Ekspor (ton)	Nilai Linguistik
1999	Jan	20,551	A2
	Feb	6,129	A1
	Mar	28,959	A3
	Apr	32,222	A3
	May	43,598	A4
⋮	⋮	⋮	⋮
2015	Apr	12,534	A1
	May	14,304	A2
	Jun	13,738	A1
	Jul	13,888	A2

Tabel 4.34 Pembentukan FLR pada kelompok komoditi 303

Tahun	Bulan	Data Aktual (Yt)	Fuzzy Logical Relationship	
			LHS	RHS
1999	Jan	20,551		
	Feb	6,129	A2	A1
	Mar	28,959	A1	A3
	Apr	32,222	A3	A3
	May	43,598	A3	A4
⋮	⋮	⋮	⋮	⋮
2015	Apr	12,534	A2	A1
	May	14,304	A1	A2
	Jun	13,738	A2	A1
	Jul	13,888	A1	A2

Tabel 4.35 menyajikan hasil dari pembentukan *Fuzzy Logical Relationship Group* (FLRG) secara kronologis pada data kelompok komoditi 303. Sedangkan tabel 4.36 menyajikan hasil pembentukan FLRG pada data kelompok komoditi 302 tanpa pengulangan (non kronologis). Pembentukan FLRG secara kronologis dan non kronologis ini akan digunakan untuk penghitungan nilai ramalan menurut masing-masing algoritma.

Tabel 4.37 Pembentukan bobot untuk peramalan pada A_1

Urutan	LHS atau Y_t	RHS atau Y_{t+1}	mid-point dari RHS
1	A5	A1	m_1
2	A5	A1	m_1
3	A5	A2	m_2
4	A5	A3	m_3
5	A5	A4	m_4
6	A5	A6	m_6

Asumsikan bahwa $Y_t = A_5$ maka nilai peramalan pada waktu $t + 1$ adalah:

$$\hat{Y}_{t+1} = \frac{m_1 + m_2 + m_3 + m_4 + m_6}{5} = \frac{1}{5} m_1 + \frac{1}{5} m_2 + \frac{1}{5} m_3 + \frac{1}{5} m_4 + \frac{1}{5} m_6$$

Langkah yang serupa juga dilakukan untuk mendapatkan nilai peramalan pada waktu $t + 1$ untuk $Y_t = A_1$ sampai dengan $Y_t = A_{10}$.

4.3.4.2 Peramalan dengan Algoritma Chen (2)

Merujuk pada tabel 4.37, peramalan dengan algoritma Chen(2) adalah sebagai berikut:

Asumsikan bahwa $Y_t = A_5$ maka nilai peramalan pada waktu $t + 1$ adalah:

$$\hat{Y}_{t+1} = \frac{m_1 + m_1 + m_2 + m_3 + m_4 + m_6}{6} = \frac{2}{6} m_1 + \frac{1}{6} m_2 + \frac{1}{6} m_3 + \frac{1}{6} m_4 + \frac{1}{6} m_6$$

Langkah yang serupa juga dilakukan untuk mendapatkan nilai peramalan pada waktu $t + 1$ untuk $Y_t = A_1$ sampai dengan $Y_t = A_{10}$.

4.3.4.3 Peramalan dengan Algoritma Yu

Merujuk pada tabel 4.37, peramalan dengan algoritma Yu adalah sebagai berikut:

Asumsikan bahwa $Y_t = A_5$ maka nilai peramalan pada waktu $t + 1$ adalah:

$$\hat{Y}_{t+1} = \frac{1m_1 + 2m_1 + 3m_2 + 4m_3 + 5m_4 + 6m_6}{21}$$

$$= \frac{3}{21} m_1 + \frac{3}{21} m_2 + \frac{4}{21} m_3 + \frac{5}{21} m_4 + \frac{6}{21} m_6$$

Langkah yang serupa juga dilakukan untuk mendapatkan nilai peramalan pada waktu $t + 1$ untuk $Y_t = A_1$ sampai dengan $Y_t = A_{10}$.

4.3.4.4 Peramalan dengan Algoritma Lee

Merujuk pada tabel 4.37, peramalan dengan algoritma Lee ($c = 1,6$) adalah sebagai berikut:

Asumsikan bahwa $Y_t = A_5$ maka nilai peramalan pada waktu $t + 1$ adalah:

$$\hat{Y}_{t+1} = \frac{1m_1 + 1,6m_1 + 2,56m_2 + 4,096m_3 + 6,55m_4 + 10,48m_6}{1 + 1,6 + 2,56 + 4,096 + 6,55 + 10,48}$$

Langkah yang serupa juga dilakukan untuk mendapatkan nilai peramalan pada waktu $t + 1$ untuk $Y_t = A_1$ sampai dengan $Y_t = A_{10}$.

4.3.4.5 Peramalan dengan Algoritma Cheng

Merujuk pada tabel 4.37, peramalan dengan algoritma Lee adalah sebagai berikut:

Asumsikan bahwa $Y_t = A_1$ maka nilai peramalan pada waktu $t + 1$ adalah:

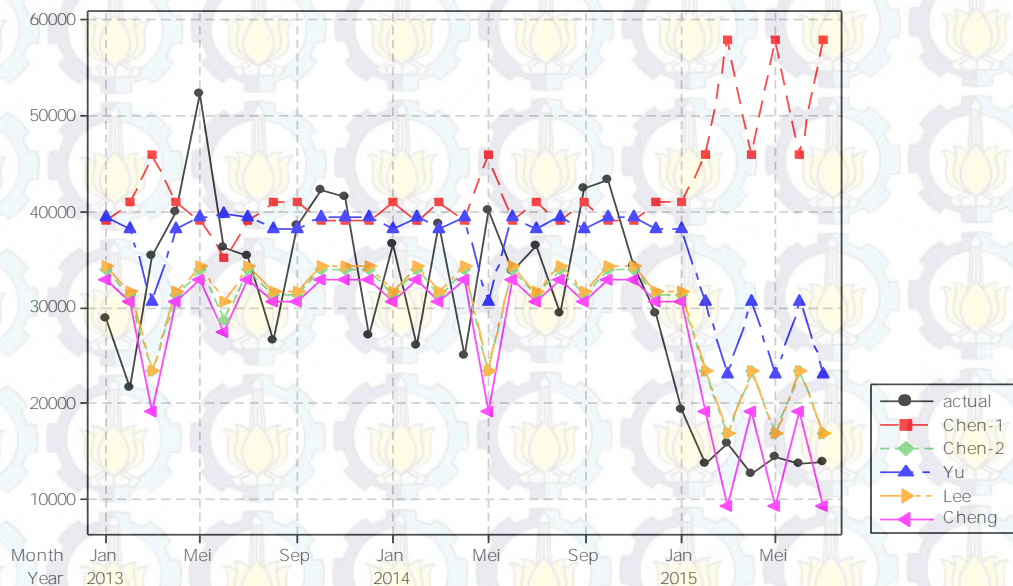
$$\begin{aligned} \hat{Y}_{t+1} &= \frac{1m_1 + 2m_1 + 1m_2 + 1m_3 + 1m_4 + 1m_6}{7} \\ &= \frac{2}{7} m_1 + \frac{1}{7} m_2 + \frac{1}{7} m_3 + \frac{1}{7} m_4 + \frac{1}{7} m_6 \end{aligned}$$

Langkah yang serupa juga dilakukan untuk mendapatkan nilai peramalan pada waktu $t + 1$ untuk $Y_t = A_1$ sampai dengan $Y_t = A_{10}$. Tabel 4.38 memperlihatkan bahwa dari keempat algoritma WFTS yang dilakukan, metode WFTS dengan algoritma Cheng menunjukkan kinerja terbaik dengan nilai MAPE minimum yakni sebesar 25,66.

Tabel 4.38 Kinerja Peramalan WFTS pada Kelompok Komoditi 303

Metode WFTS	RMSE	MAPE
Chen-1	18,985	74.7722
Chen-2	8,461	27.0753
Yu-1	10,070	38.7660
Lee	7,187	27.0256
Cheng	8,493	25.6558


Secara visual, hasil peramalan metode WFTS menurut algoritma dibandingkan dengan nilai aktual sebagai berikut:



Gambar 4.19 Perbandingan Hasil Peramalan WFTS pada Kelompok Komoditi 303

Melalui gambar 4.19 diatas, terlihat bahwa hasil peramalan WFTS dengan algoritma Chen-2, Yu, dan Cheng memiliki pola yang menyerupai pola data aktual. Sedangkan hasil peramalan menurut algoritma Lee tampak berbeda jauh dengan pola data aktual. Hal ini didukung dengan nilai MAPE terbesar (lihat tabel 4.25) yang menunjukkan kinerja peramalan yang kurang memuaskan pada kelompok komoditi 303.

4.3.5 Perbandingan Hasil Peramalan pada Kelompok Komoditi 303



Gambar 4.20 Perbandingan Hasil Peramalan pada Kelompok Komoditi 303

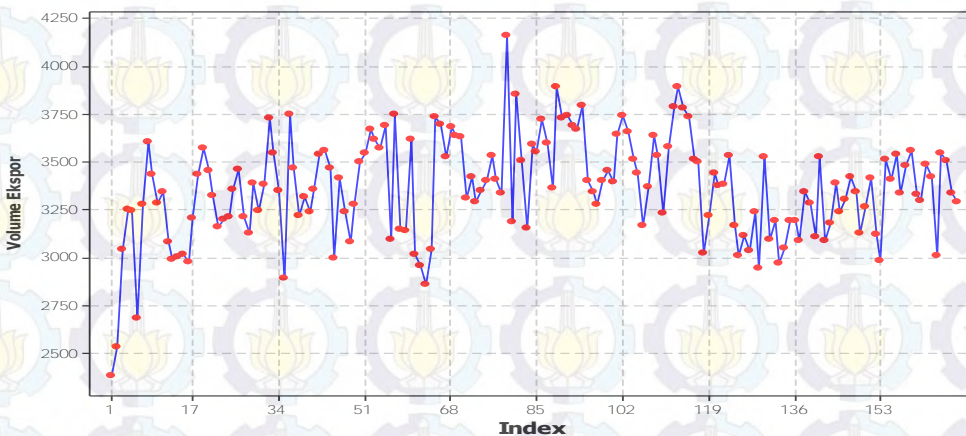
Melalui gambar 4.20, terlihat bahwa peramalan yang dilakukan dengan metode hibrida ARIMA-NN dan ARIMA hampir berhimpitan, dan paling mendekati nilai aktual.

4.4 Kelompok Komoditi 306

4.4.1 Pemodelan dengan ARIMA Box-Jenkins

Pada bagian ini disajikan bagaimana memperoleh model ARIMA terbaik menurut prosedur Box-Jenkins.


1. Plot data *training* Januari 1999 s.d Desember 2012



Gambar 4.21 Plot Data *Training* Kelompok Komoditi 306

Plot data *training* pada gambar 4.21 memperlihatkan bahwa pola data volume ekspor untuk kelompok komoditi 306 menunjukkan variasi yang tidak jauh berbeda dari tahun ke tahun. Namun demikian, perlu dilakukan pengujian terhadap asumsi stasioneritas dalam varians dan nilai rata-rata.

2. Transformasi Box-Cox dan Uji Unit Root ADF



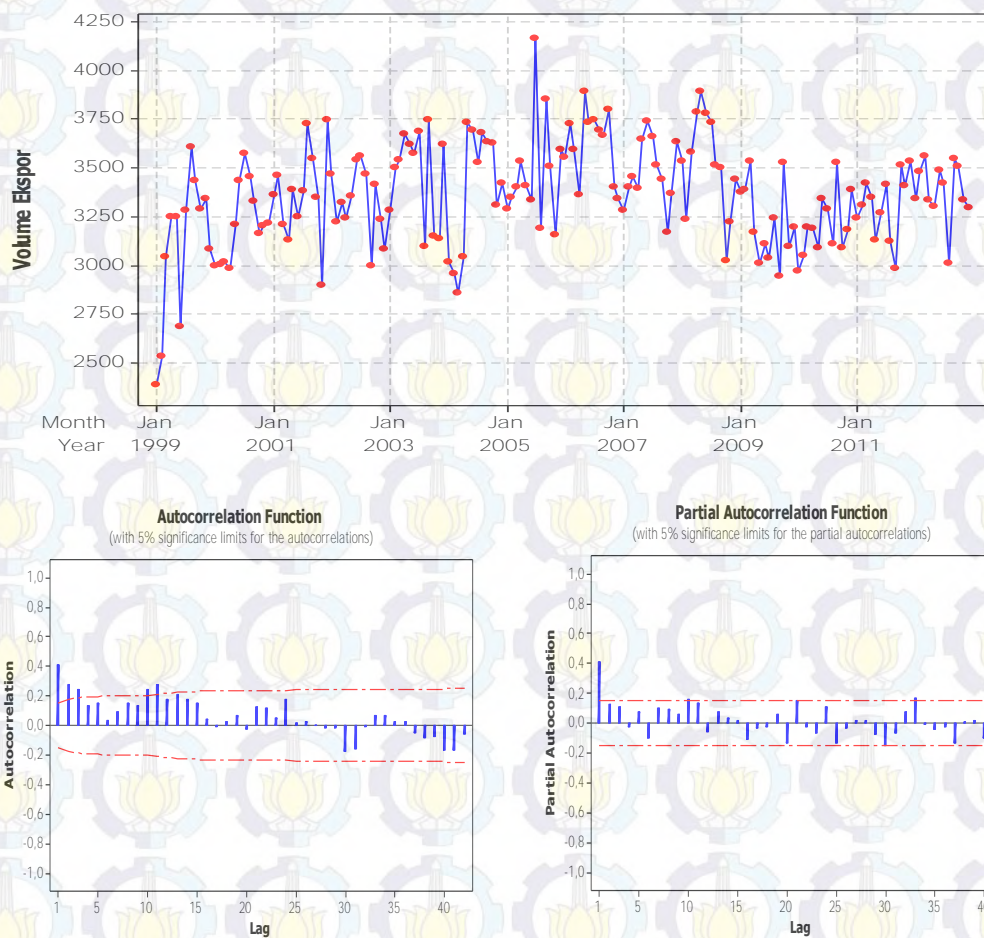
Gambar 4.22 Box-Cox Plot untuk Kelompok Komoditi 306

Asumsi stasioneritas dalam varians diuji dengan melakukan Box-Cox transformasi, seperti pada gambar 4.22. Melalui gambar 4.21, terlihat bahwa nilai lambda sebesar 0,5 yang berarti data kelompok komoditi 306 memerlukan transformasi akar kuadrat untuk mencapai stasioneritas dalam varians. Selanjutnya, asumsi stasioneritas dalam nilai rata-rata diuji melalui uji *Augmented Dickey-Fuller* yang hasilnya dapat dilihat pada tabel 4.28. Melalui Tabel 4.28, hasil uji *Augmented Dickey-Fuller* menunjukkan bahwa $\tau_{hitung} < \tau_{tabel}$, sehingga keputusannya adalah tolak H_0 yang berarti data telah stasioner dalam *mean* dan tidak diperlukan prosedur *differencing*. Adapun uji *Augmented Dickey-Fuller* (ADF) yang dilakukan adalah pada tipe level, sehingga keputusan tolak H_0 juga berarti bahwa data telah memenuhi asumsi stasioner pada level.

Tabel 4.39 Hasil Uji Augmented Dickey-Fuller Kelompok Komoditi 306

Parameter	Estimasi	Std Error	τ_{hitung}	τ_{tabel} (5%)	Keputusan
δ	-0,545894	0,079950	-6,827934	-2,878937	Tolak H_0

3. Plot data *training*, ACF, dan PACF setelah transformasi



Gambar 4.23 Plot Data dan Pola ACF, PACF sesudah transformasi

Setelah dilakukan transformasi akar kuadrat, plot data kelompok komoditi 306 dapat dilihat pada gambar 4.23 berikut dengan pola ACF dan PACF. Plot data setelah transformasi menunjukkan bahwa pola data telah menunjukkan kestasioneran baik dalam *mean* maupun dalam varians. Melalui pola ACF, terlihat bahwa nilai autokorelasi keluar dari batas pada lag 1, 2, 3, 10, dan 11. Sedangkan pada pola PACF, nilai autokorelasi hanya melewati batas pada lag pertama. Selanjutnya dilakukan pengujian parameter berikut *diagnostic check* dengan mengidentifikasi sejumlah dugaan kemungkinan model sementara. Model terbaik yang diperoleh merupakan model yang signifikan pada pengujian parameter dan memenuhi cek diagnosa.

4. Estimasi Parameter dan Diagnostic Check

Tabel 4.40 Uji Estimasi Parameter dan Diagnostic Check

Model	Parameter Estimates	AIC	SBC	L-Jung Box	White noise	Normality
(1,0,0)	sig	2319,135	2325,383	no	sig	normal
(0,0,1)	sig	2328,164	2334,412	no	no	Normal
(0,0,2)	sig	2324,845	2334,217	no	no	Normal
(0,0,3)	sig	2319,132	2331,628	no	no	Normal
(1,0,1)	sig	2315,095	2324,467	no	no	Normal
(1,0,2)	sig	2315,936	2328,432	no	no	Normal
(0,0,[10])	sig	2340,41	2346,658	no	no	Normal
(0,0,[11])	sig	2340,416	2340,664	no	no	Normal
(1,0,[10])	sig	2315,319	2324,691	no	no	Normal
(1,0,[11])	sig	2316,149	2325,52	no	sig	Normal
(0,0,[1,10])	sig	2327,051	2336,423	no	sig	Normal
(0,0,[2,10])	sig	2334,026	2343,398	no	no	Normal
(0,0,[3,10])	sig	2338,367	2347,739	no	no	Normal
(0,0,[1,11])	sig	2325,249	2334,62	no	no	Normal
(0,0,[2,11])	sig	2334,308	2343,68	no	no	Normal
(0,0,[3,11])	sig	2337,746	2347,118	no	no	Normal
(1,0,[1,10])	sig	2310,712	2323,208	sig	sig	Normal
(1,0,[1,11])	sig	2312,829	2325,325	no	sig	normal

Melalui tabel 4.40, terlihat bahwa model yang memenuhi uji signifikansi parameter dan cek diagnosa adalah model ARIMA (1,0,[1,10]) dimana hasil estimasi paramater dapat dilihat pada tabel 4.41.

Tabel 4.41. Estimasi Parameter dan Uji Signifikansi Parameter Model ARIMA (1,0,[1,10])

Parameter	Estimasi	p-value	Keputusan
MU	3344,8	<0,0001	Signifikan
MA1,1	0,45055	0,0004	Signifikan
MA1,2	-0,17889	0,0132	Signifikan
AR1,1	0,76577	<0,0001	Signifikan

Tabel 4.42 Nilai Statistik Uji Chi-Square Residual Model ARIMA (1,0,[1,10]) pada data kelompok komoditi 306

Lag	χ^2 hitung	p-value	keputusan
6	3.97	0.2645	Gagal tolak Ho
12	6	0.7402	Gagal tolak Ho
18	10.94	0.7568	Gagal tolak Ho
24	26.64	0.1831	Gagal tolak Ho
30	34.54	0.1508	Gagal tolak Ho
36	45.41	0.0736	Gagal tolak Ho
42	49.98	0.1119	Gagal tolak Ho
48	56.4	0.1186	Gagal tolak Ho


Dari tabel 4.42 diatas dapat dilihat bahwa nilai p-value dari statistik uji Chi-Square sampai dengan lag ke-48 lebih besar dari 0,05 sehingga memberikan kesimpulan bahwa model ARIMA (1,0,[1,10]) sudah memenuhi asumsi *white noise*. Selanjutnya pengujian asumsi normalitas dilakukan dengan uji Kolomogorov-Smrinov. Hipotesis awal yang digunakan adalah residual model berdistribusi normal. Hasil pengujian asumsi normalitas pada tingkat signifikansi 0,05 memberikan nilai statistik uji D sebesar 0,061627 dan p-value sebesar 0,161. Dengan demikian dapat disimpulkan bahwa model untuk kelompok komoditi 306 adalah ARIMA (1,0,[1,10]) dengan persamaan sebagai berikut:

$$\hat{Z}_t = \phi_1 Z_{t-1} + e_t + \theta_1 e_{t-1} - \theta_{10} e_{t-10}$$

$$\hat{Z}_t = 0,77Z_{t-1} + e_t - 0,45e_{t-1} + 0,18e_{t-10}$$

Model diatas menjelaskan bahwa besarnya volume ekspor perikanan untuk kelompok komoditi 306 berkaitan dengan volume ekspor pada bulan sebelumnya.

5. Peramalan dengan model ARIMA terbaik



Gambar 4.24 Peramalan 12 bulan berikutnya pada kelompok komoditi 306

4.4.2 Pemodelan dengan FFNN

Setelah dilakukan data *preprocessing* yaitu *scaling* data dan pemilihan variabel input berdasarkan lag *autoregressive*, dilakukan pemodelan dan peramalan volume ekspor perikanan untuk kelompok komoditi 306 dengan metode FFNN. Untuk mendapatkan arsitektur optimal, dilakukan kombinasi pengujian 1 s.d 10 *hidden neuron* dengan maksimum iterasi (*epoch*) 10000 dan dilakukan pengulangan percobaan sebanyak 5 kali dengan initial weight yang berbeda di setiap percobaan.


Tabel 4.43 Kinerja Peramalan FFNN untuk Kelompok Komoditi 306 dengan Input Lag 1

Jumlah Hidden Node	Percobaan 1	Percobaan 2	Percobaan 3	Percobaan 4	Percobaan 5
1	-672.373	-669.828	-665.639	-669.986	-659.599
2	-675.394	-627.885	-588.909	-675.394	-612.633
3	-571.898	-670.22	-669.148	-670.606	-668.558
4	-508.646	-665.75	-663.957	-625.01	-638.823
5	-619.298	-501.356	-663.027	-647.039	-644.588
6	-649.247	-655.925	-652.215	-649.879	-555.952
7	-579.818	-508.281	-631.283	-634.017	-602.799
8	-602.891	-657.63	-656.411	-631.811	-648.571
9	-646.321	-614.694	-526.143	-611.55	-653.856
10	-638.329	-645.754	-614.62	-631.852	-630.425

Melalui tabel 4.43 terlihat bahwa setelah melalui 5 kali percobaan dengan kombinasi *hidden neuron* sebanyak 10 kombinasi, diperoleh nilai AIC minimum pada kombinasi 2 *hidden neuron* pada percobaan ke-4. Kinerja *hidden neuron* tersebut ditunjukkan dengan nilai AIC sebesar -657,394. Dengan demikian arsitektur FFNN optimal untuk volume ekspor perikanan pada kelompok komoditi 306 adalah NN(1;2;1) yang berarti terdapat sebanyak 1 (satu) buah variabel input pada input *layer* dengan 2 (dua) buah *hidden neuron* pada *hidden layer* dan 1 (satu) variabel output. Rincian bobot berdasarkan arsitektur FFNN optimal yakni NN(1;2;1) dapat dilihat pada tabel 4.33.

Tabel 4.44 Rincian Bobot NN(1;2;1)

Bobot akhir input <i>hidden</i>	Bobot akhir bias <i>hidden</i>	Bobot akhir <i>hidden</i> output	Bobot akhir bias output
(1)	(2)	(3)	(4)
-1,9614	874,7707	0,2234	-0,3685
-0,0064	-1,8037	1,0395	



Gambar 4.25 Arsitekur NN(1;2;1) untuk kelompok komoditi 306

Berdasarkan persamaan 2.28 dan fungsi aktivasi pada persamaan 2.29 maka model NN(1;2;1) untuk kelompok komoditi 306 ekspor perikanan secara matematis dapat ditulis sebagai berikut:

$$\hat{Y}_t = b^o + w_1^o f_1^h + w_2^o f_2^h$$

$$\hat{Y}_t = -0,37 + 0,22f_1^h + 1,04f_2^h$$

dengan:

$$f_1^h = \frac{1}{1 + e^{-[874,77 - 1,96Y_{t-1}]}}$$

$$f_2^h = \frac{1}{1 + e^{-[-1,8 - 0,006Y_{t-1}]}}$$

Jika dimisalkan $\hat{Y}_{a,t}$ sebagai $\hat{Y}_{a,t(sv)}$ dimana (sv) merupakan notasi yang menunjukkan bahwa output dari FFNN masih dalam bentuk *scaled value*, maka

nilai peramalan dengan metode FFNN berdasarkan persamaan (2.28) secara matematis dapat ditulis sebagai berikut:

$$\hat{Y}_{a,t(0)} = \hat{Y}_{a,t(sv)} \cdot (\max(Y) - \min(Y) + \min(Y))$$

dimana $\max(Y)$ merupakan nilai maksimum dari deret waktu, dan $\min(Y)$ merupakan nilai minimum dari deret waktu, dan $\hat{Y}_{a,t(0)}$ merupakan nilai peramalan setelah melalui *postprocessing*. Dengan demikian model FFNN dapat ditulis sebagai berikut:

$$\hat{Y}_{a,t(0)} = 11.645.570 \hat{Y}_{a,t(sv)} + 5.695.443$$

4.4.3 Pemodelan dengan Hibrida ARIMA-NN

Pemodelan dengan Hibrida ARIMA-NN dilakukan dengan menjadikan residual pada ARIMA sebagai input., dimana pemilihan variabel input juga berdasarkan lag *autoregressive* yang telah melalui proses *scaling*. Dengan kombinasi jumlah *hidden neuron* sebanyak 1 s.d 10 dan diulangi sebanyak 5 kali percobaan diperoleh hasil seperti dalam tabel berikut ini:

Tabel 4.45 Kinerja Peramalan Hibrida ARIMA-NN untuk Kelompok Komoditi 306 dengan Input Lag 1

Jumlah Hidden Node	Percobaan 1	Percobaan 2	Percobaan 3	Percobaan 4	Percobaan 5
1	-665.392	-652.457	-667.098	-665.868	-664.835
2	-642.471	-665.522	-662.781	-657.501	-665.522
3	-664.977	-665.076	-665.075	-665.076	-665.076
4	-651.987	-644.307	-662.057	-655.86	-659.992
5	-654.209	-653.062	-642.206	-654.08	-654.453
6	-620.84	-649.584	-644.018	-639.042	-647.513
7	-647.618	-636.018	-642.985	-635.69	-634.925
8	-626.253	-636.611	-633.03	-637.208	-629.346
9	-618.848	-624.016	-627.378	-623.21	-648.376
10	-625.536	-621.067	-625.655	-614.064	-628.031

Melalui tabel 4.45 diketahui nilai minimum dari AIC yakni sebesar -667,098 pada percobaan ke-3 dengan 1 (satu) unit *hidden neuron* pada *hidden layer*. Dengan demikian arsitektur hibrida ARIMA-NN yang diperoleh adalah NN(1;1;1) dimana rincian nilai bobot dapat dilihat pada tabel berikut:

Tabel 4.46 Rincian Bobot Hibrida ARIMA-NN (1;1;1)

Bobot akhir input <i>hidden</i>	Bobot akhir bias <i>hidden</i>	Bobot akhir <i>hidden</i> output	Bobot akhir bias output
2,602	759,0749	-0,7837	-0,9323

Berdasarkan tabel 4.46 diatas, model arsitektur NN(1;1;1) untuk peramalan residual ARIMA dari volume ekspor perikanan untuk kelompok komoditi 306 dapat ditulis secara matematis sebagai berikut:

$$\hat{\varepsilon}_{a,t} = -0,93 - 0,78 f_1^h$$

$$f_1^h = \frac{1}{1 + e^{-[759,07 + 2,6 \hat{\varepsilon}_{a,t-1}]}}$$

Untuk keperluan *postprocessing*, residual ARIMA dikembalikan ke ukuran nilai sebenarnya dan digunakan nilai minimum residual ARIMA yaitu -991,7957 dan nilai maksimum residual yaitu 733,0004 sehingga model matematisnya adalah sebagai berikut:

$$\hat{\varepsilon}_{a,t(0)} = 1724,7961 \hat{\varepsilon}_{a,t(sv)} - 991,7957$$

Setelah menggabungkan model ARIMA (1,0,[1,10]) dengan model FFNN residual ARIMA, maka model hibrida ARIMA-NN untuk volume ekspor perikanan pada kelompok komoditi 306 secara matematis dapat ditulis sebagai berikut:

$$\hat{Z}_t = \hat{Z}_{L,t} + \hat{Z}_{N,t}$$

dengan

$$\hat{Z}_{L,t} = \hat{Z}_t = 3344,8 + \frac{(1 - 0,45B - 0,18B^{10})}{(1 - 0,77B)} e_t$$

dan $\hat{Z}_{N,t} = 1724,80 \hat{\varepsilon}_{a,t(sv)} - 991,80$

Dimana $\hat{\varepsilon}_{a,t(sv)}$ merupakan output residual ARIMA dalam bentuk *scaled value* dari metode FFNN.

4.4.4 Pemodelan dengan WFTS

Pemodelan dengan WFTS dilakukan dengan beberapa algoritma, yakni algoritma Chen, Yu, dan Cheng. Langkah pertama yang dilakukan pada ketiga algoritma tersebut adalah mendefinisikan himpunan sampel dan interval sebagai gambaran, dimana himpunan sampel dibagi ke dalam 24 bagian dengan panjang interval sebesar 500.000 (tabel 4.47).

Tabel 4.47 Himpunan *Fuzzy* pada 24 Bagian Sampel

No	Universe of Discourse - U(t)		Fuzzy sets - A(i)	Mid point - m(i)
	U(t)_lower	U(t)_upper		
1	5,500,000	6,000,000	A01	5,750,000
2	6,000,000	6,500,000	A02	6,250,000
3	6,500,000	7,000,000	A03	6,750,000
4	7,000,000	7,500,000	A04	7,250,000
5	7,500,000	8,000,000	A05	7,750,000
6	8,000,000	8,500,000	A06	8,250,000
7	8,500,000	9,000,000	A07	8,750,000
8	9,000,000	9,500,000	A08	9,250,000
⋮	⋮	⋮	⋮	⋮
18	14,000,000	14,500,000	A18	14,250,000
19	14,500,000	15,000,000	A19	14,750,000
20	15,000,000	15,500,000	A20	15,250,000
21	15,500,000	16,000,000	A21	15,750,000
22	16,000,000	16,500,000	A22	16,250,000
23	16,500,000	17,000,000	A23	16,750,000
24	17,000,000	17,500,000	A24	17,250,000

Setelah dibentuk himpunan *fuzzy* dan diperoleh nilai *fuzzy* dari data, selanjutnya membentuk FLR dan FLRG untuk masing-masing algoritma Chen,

Yu, Cheng, dan Lee. Hasil pembentukan FLR dan FLRG beserta defuzzy berdasarkan masing-masing algoritma dapat dilihat pada tabel berikut.

Tabel 4.48 Pembentukan FLRG pada kelompok komoditi 306

Tahun	Bulan	Volume Ekspor (kg)	Fuzzy Logical Relationship	
			LHS	RHS
1999	Jan	5,695,443		
	Feb	6,415,306	A1	A2
	Mar	9,278,122	A2	A8
	Apr	10,566,368	A8	A11
	May	10,552,258	A11	A16
⋮	⋮	⋮	⋮	⋮
2015	Apr	13,990,548	A16	A17
	May	12,609,148	A17	A15
	Jun	13,479,629	A15	A16
	Jul	10,970,578	A16	A11

Selanjutnya, setelah dilakukan defuzzy, dilakukan perbandingan kinerja peramalan antara masing-masing algoritma WFTS tersebut seperti terlihat dalam tabel 4.49 berikut.


Tabel 4.49 Perbandingan Kinerja Peramalan antar Algoritma pada WFTS

Metode WFTS	RMSE	MAPE
Chen-1	5,252,273	26.1894
Chen-2	1,518,630	9.6594
Yu	1,586,039	9.8908
Lee	1,993,578	13.2309
Cheng	1,521,448	9.2991

Melalui tabel 4.49 ternyata metode WFTS yang diterapkan pada data volume ekspor perikanan untuk kelompok komoditi 306 menghasilkan performa terbaik berdasarkan nilai minimum RMSE adalah algoritma Yu dengan nilai RMSE sebesar 1.586.039. Sedangkan jika dibandingkan berdasarkan nilai MAPE, maka algoritma WFTS dengan performa terbaik adalah algoritma Cheng, dengan nilai MAPE sebesar 9,2991.

4.4.5 Hasil dan Perbandingan Kinerja Peramalan untuk Kelompok Komoditi 306

Berdasarkan sejumlah metode yang telah diterapkan untuk melakukan peramalan volume ekspor perikanan Indonesia untuk kelompok komoditi 306, Gambar 4.26 memperlihatkan perbandingan hasil peramalan tersebut.



Gambar 4.26 Perbandingan hasil peramalan seluruh metode peramalan

Melalui gambar 4.26 terlihat bahwa hasil peramalan yang paling mendekati nilai aktual adalah peramalan dengan metode WFTS dengan algoritma Cheng. Peramalan dengan metode FFNN terlihat menunjukkan pola yang cukup jauh berbeda dengan pola data aktual.



BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Beberapa kesimpulan yang dapat diambil dari analisis dan pembahasan adalah sebagai berikut:

1. Dari sejumlah metode peramalan yang digunakan dalam peramalan terhadap volume ekspor perikanan untuk kelompok komoditi 302, metode WFTS dengan algoritma Cheng menunjukkan kinerja terbaik mengungguli metode peramalan lainnya dengan nilai MAPE sebesar 26,34 %. Dengan kata lain, metode peramalan WFTS merupakan metode peramalan yang paling mendekati nilai aktual dari volume ekspor perikanan. Namun demikian, nilai MAPE masih berada pada rentang diatas 10 %.
2. Dari sejumlah metode peramalan yang digunakan dalam peramalan terhadap volume ekspor perikanan untuk kelompok komoditi 303, metode hibrida ARIMA-NN menunjukkan kinerja terbaik mengungguli metode peramalan lainnya dengan nilai MAPE sebesar 21,50 %. Dengan kata lain, metode peramalan WFTS merupakan metode peramalan yang paling mendekati nilai aktual dari volume ekspor perikanan. Namun demikian, nilai MAPE masih berada pada rentang diatas 10 %.
3. Dari sejumlah metode peramalan yang digunakan dalam peramalan terhadap volume ekspor perikanan untuk kelompok komoditi 302, metode WFTS dengan algoritma Cheng menunjukkan kinerja terbaik mengungguli metode peramalan lainnya dengan nilai MAPE sebesar 9,41 %. Dengan kata lain, metode peramalan WFTS merupakan metode peramalan yang paling mendekati nilai aktual dari volume ekspor perikanan.

5.2 Saran

Berdasarkan hal-hal yang telah disimpulkan diatas, terdapat beberapa hal yang dapat disarankan bagi pengembangan penelitian selanjutnya, antara lain:

1. Penelitian ini menggunakan tiga metode yakni ARIMA, *Neural Network* (terdiri atas FFNN dan Hibrida ARIMA-NN), serta WFTS (menurut algoritma Chen, Yu, Lee, dan Cheng). Pengembangan terhadap penelitian ini dapat dilakukan dengan mengkombinasikan metode NN dengan WFTS ataupun dengan metode peramalan lainnya.
2. Untuk meningkatkan kualitas dan kinerja hasil peramalan, penelitian selanjutnya diharapkan dapat melibatkan faktor lain yang diduga mempengaruhi volume ekspor perikanan, misalnya produksi perikanan Indonesia per bulan.

Lampiran 1.

Volume Ekspor Perikanan Indonesia periode Januari 1999 - Juli 2015

Kelompok komoditi : 302

(kg)

Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor
1999	Jan	7,054,383	2002	Jan	7,992,930	2005	Jan	7,295,373
	Feb	6,526,347		Feb	6,094,829		Feb	8,008,690
	Mar	15,860,445		Mar	7,581,321		Mar	8,063,104
	Apr	9,301,213		Apr	6,774,787		Apr	9,267,906
	May	16,631,068		May	7,203,311		May	8,395,499
	Jun	7,611,961		Jun	6,405,522		Jun	8,037,221
	Jul	11,038,313		Jul	6,008,597		Jul	10,584,292
	Aug	12,039,677		Aug	6,586,467		Aug	7,553,437
	Sep	18,581,130		Sep	5,239,207		Sep	8,497,443
	Oct	8,433,126		Oct	6,130,509		Oct	7,624,777
	Nov	12,182,926		Nov	5,274,925		Nov	6,435,865
	Dec	16,095,861		Dec	8,386,750		Dec	9,651,434
2000	Jan	8,903,203	2003	Jan	8,222,906	2006	Jan	7,419,477
	Feb	5,991,853		Feb	4,286,619		Feb	7,074,808
	Mar	13,045,024		Mar	7,093,513		Mar	6,033,354
	Apr	11,951,467		Apr	6,354,937		Apr	6,299,351
	May	9,709,088		May	6,578,961		May	7,055,571
	Jun	9,737,945		Jun	6,208,253		Jun	6,486,024
	Jul	8,251,169		Jul	6,353,455		Jul	6,475,041
	Aug	8,501,694		Aug	6,371,801		Aug	7,707,078
	Sep	8,342,327		Sep	5,763,705		Sep	6,998,054
	Oct	7,715,665		Oct	10,732,915		Oct	7,590,572
	Nov	8,377,906		Nov	7,836,084		Nov	6,405,720
	Dec	7,268,010		Dec	7,958,965		Dec	8,273,389
2001	Jan	8,552,833	2004	Jan	7,183,703	2007	Jan	7,554,860
	Feb	5,564,638		Feb	9,917,603		Feb	7,612,032
	Mar	6,493,203		Mar	6,208,462		Mar	7,945,017
	Apr	7,975,683		Apr	5,724,273		Apr	8,733,432
	May	7,326,446		May	7,232,065		May	14,957,952
	Jun	7,235,146		Jun	6,684,184		Jun	8,197,636
	Jul	9,219,976		Jul	5,339,284		Jul	11,187,603
	Aug	8,164,496		Aug	8,097,438		Aug	9,115,782
	Sep	7,840,219		Sep	8,299,356		Sep	7,674,550
	Oct	7,837,615		Oct	8,824,690		Oct	7,953,992
	Nov	6,402,398		Nov	5,445,890		Nov	9,746,230
	Dec	8,517,614		Dec	8,498,457		Dec	12,691,515

(lanjutan)

Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor
2008	Jan	10,447,779	2011	Jan	10,915,219	2014	Jan	5,225,220
	Feb	7,770,096		Feb	5,784,497		Feb	4,399,982
	Mar	10,129,060		Mar	11,347,347		Mar	5,863,288
	Apr	11,089,708		Apr	6,725,896		Apr	8,574,756
	May	10,825,233		May	7,018,043		May	6,032,102
	Jun	9,661,956		Jun	6,417,391		Jun	5,390,680
	Jul	9,281,583		Jul	6,801,487		Jul	5,060,850
	Aug	8,625,560		Aug	5,779,764		Aug	4,439,208
	Sep	9,656,688		Sep	5,135,891		Sep	5,311,463
	Oct	10,893,862		Oct	7,702,613		Oct	5,821,206
	Nov	11,917,783		Nov	8,217,158		Nov	6,003,223
	Dec	8,550,342		Dec	8,153,845		Dec	5,940,900
2009	Jan	9,543,051	2012	Jan	11,203,761	2015	Jan	5,338,378
	Feb	7,422,335		Feb	9,857,094		Feb	4,616,353
	Mar	8,280,528		Mar	5,998,049		Mar	5,736,042
	Apr	9,355,610		Apr	7,596,678		Apr	6,079,204
	May	9,656,414		May	8,360,558		May	5,905,763
	Jun	9,986,571		Jun	6,414,969		Jun	5,476,311
	Jul	9,317,897		Jul	5,898,288		Jul	4,609,800
	Aug	8,582,921		Aug	6,903,719			
	Sep	7,856,517		Sep	6,526,128			
	Oct	9,034,512		Oct	8,406,865			
	Nov	7,904,147		Nov	7,661,563			
	Dec	8,782,523		Dec	7,000,058			
2010	Jan	8,296,827	2013	Jan	5,723,638			
	Feb	7,218,185		Feb	16,525,978			
	Mar	8,376,240		Mar	5,881,833			
	Apr	8,720,974		Apr	7,849,281			
	May	9,413,534		May	7,012,080			
	Jun	9,337,081		Jun	6,420,241			
	Jul	7,571,822		Jul	7,645,293			
	Aug	7,367,363		Aug	5,386,924			
	Sep	5,885,727		Sep	5,451,201			
	Oct	7,678,146		Oct	6,366,876			
	Nov	7,902,694		Nov	6,605,140			
	Dec	7,762,613		Dec	17,202,909			

Sumber: BPS

Lampiran 2.

Volume Ekspor Perikanan Indonesia periode Januari 1999 - Juli 2015

Kelompok komoditi : 303

(kg)

Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor
1999	Jan	20,550,895	2002	Jan	6,992,329	2005	Jan	45,956,520
	Feb	6,128,585		Feb	4,349,569		Feb	19,591,931
	Mar	28,958,622		Mar	5,900,539		Mar	27,455,278
	Apr	32,221,690		Apr	5,436,425		Apr	23,351,813
	May	43,597,565		May	10,490,490		May	14,480,815
	Jun	22,782,191		Jun	56,149,642		Jun	20,714,180
	Jul	18,856,862		Jul	13,626,942		Jul	21,166,123
	Aug	21,720,553		Aug	8,813,862		Aug	40,590,362
	Sep	12,403,633		Sep	8,980,976		Sep	22,154,733
	Oct	11,505,301		Oct	11,973,068		Oct	14,051,588
	Nov	10,367,023		Nov	7,670,308		Nov	24,918,756
	Dec	7,713,308		Dec	5,902,227		Dec	30,657,536
2000	Jan	8,017,214	2003	Jan	4,612,234	2006	Jan	36,759,760
	Feb	2,571,709		Feb	16,891,946		Feb	14,136,102
	Mar	10,459,902		Mar	15,988,724		Mar	14,880,123
	Apr	10,025,992		Apr	6,756,215		Apr	11,571,639
	May	9,341,922		May	39,255,360		May	147,296,175
	Jun	21,618,414		Jun	25,028,106		Jun	8,729,007
	Jul	5,665,831		Jul	7,338,512		Jul	30,298,159
	Aug	11,040,837		Aug	93,132,293		Aug	20,871,696
	Sep	11,941,983		Sep	21,067,438		Sep	16,723,141
	Oct	4,895,140		Oct	49,465,251		Oct	9,028,447
	Nov	4,995,122		Nov	15,328,516		Nov	13,709,816
	Dec	9,035,864		Dec	95,804,786		Dec	13,347,210
2001	Jan	7,204,842	2004	Jan	3,061,308	2007	Jan	17,561,598
	Feb	3,626,032		Feb	51,136,595		Feb	11,733,198
	Mar	4,282,321		Mar	2,853,081		Mar	12,049,966
	Apr	5,531,226		Apr	3,789,931		Apr	13,421,296
	May	6,192,030		May	11,533,578		May	15,690,292
	Jun	5,213,962		Jun	7,544,016		Jun	12,271,961
	Jul	6,474,537		Jul	7,611,089		Jul	18,721,896
	Aug	6,674,996		Aug	32,825,937		Aug	18,190,539
	Sep	3,739,891		Sep	25,691,630		Sep	22,021,659
	Oct	5,999,401		Oct	84,289,416		Oct	16,386,691
	Nov	3,706,425		Nov	154,422,600		Nov	22,106,747
	Dec	7,472,575		Dec	33,263,609		Dec	25,811,195

lanjutan

Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor
2008	Jan	10,507,834	2011	Jan	29,956,661	2014	Jan	36,547,415
	Feb	7,757,108		Feb	26,252,563		Feb	25,936,982
	Mar	8,987,832		Mar	23,360,363		Mar	38,715,329
	Apr	12,078,055		Apr	25,080,735		Apr	24,884,503
	May	14,990,469		May	35,459,643		May	40,145,021
	Jun	16,405,342		Jun	22,387,191		Jun	33,804,795
	Jul	16,537,857		Jul	24,476,825		Jul	36,495,212
	Aug	17,989,252		Aug	27,298,845		Aug	29,321,144
	Sep	19,882,563		Sep	26,869,902		Sep	42,358,027
	Oct	17,993,553		Oct	62,937,072		Oct	43,408,103
	Nov	19,656,955		Nov	39,643,467		Nov	34,357,559
	Dec	69,608,664		Dec	53,411,387		Dec	29,369,002
2009	Jan	17,260,835	2012	Jan	27,710,174	2015	Jan	19,372,024
	Feb	11,174,104		Feb	34,222,292		Feb	13,590,540
	Mar	25,443,930		Mar	35,275,223		Mar	15,843,933
	Apr	15,658,090		Apr	35,524,658		Apr	12,533,691
	May	28,813,144		May	40,366,928		May	14,303,882
	Jun	23,664,219		Jun	30,729,149		Jun	13,737,613
	Jul	14,825,775		Jul	29,821,624		Jul	13,887,808
	Aug	13,827,040		Aug	24,935,638			
	Sep	13,108,184		Sep	38,722,486			
	Oct	27,257,392		Oct	46,085,680			
	Nov	27,065,397		Nov	40,415,982			
	Dec	23,392,685		Dec	47,234,744			
2010	Jan	22,750,006	2013	Jan	28,928,626			
	Feb	26,021,147		Feb	21,682,130			
	Mar	22,983,463		Mar	35,329,236			
	Apr	40,658,288		Apr	39,919,307			
	May	53,346,398		May	52,326,182			
	Jun	60,626,932		Jun	36,336,444			
	Jul	27,137,378		Jul	35,383,813			
	Aug	19,994,816		Aug	26,544,345			
	Sep	34,354,071		Sep	38,523,826			
	Oct	31,313,395		Oct	42,202,998			
	Nov	30,953,278		Nov	41,555,557			
	Dec	40,405,594		Dec	27,074,581			

Sumber: BPS

Lampiran 3.

Volume Ekspor Perikanan Indonesia periode Januari 1999 - Juli 2015

Kelompok komoditi : 306

(kg)

Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor
1999	Jan	5,695,443	2002	Jan	12,025,698	2005	Jan	10,826,333
	Feb	6,415,306		Feb	10,378,664		Feb	11,210,015
	Mar	9,278,122		Mar	11,027,134		Mar	11,581,456
	Apr	10,566,368		Apr	10,501,516		Apr	12,492,711
	May	10,552,258		May	11,283,298		May	11,613,809
	Jun	7,223,982		Jun	12,547,972		Jun	11,127,439
	Jul	10,757,737		Jul	12,674,694		Jul	17,341,013
	Aug	12,997,734		Aug	12,026,588		Aug	10,171,504
	Sep	11,810,901		Sep	8,998,003		Sep	14,839,387
	Oct	10,801,453		Oct	11,660,850		Oct	12,292,363
	Nov	11,190,655		Nov	10,485,753		Nov	9,961,463
	Dec	9,521,773		Dec	9,523,920		Dec	12,932,123
2000	Jan	8,967,039	2003	Jan	10,759,735	2006	Jan	12,645,353
	Feb	9,011,003		Feb	12,243,453		Feb	13,884,501
	Mar	9,117,207		Mar	12,566,071		Mar	12,937,486
	Apr	8,889,447		Apr	13,496,878		Apr	11,324,131
	May	10,294,603		May	13,105,398		May	15,135,424
	Jun	11,814,237		Jun	12,787,678		Jun	13,934,656
	Jul	12,769,864		Jul	13,623,780		Jul	14,022,165
	Aug	11,954,453		Aug	9,596,505		Aug	13,646,279
	Sep	11,064,168		Sep	14,060,977		Sep	13,466,907
	Oct	9,997,673		Oct	9,920,633		Oct	14,426,018
	Nov	10,258,086		Nov	9,855,024		Nov	11,587,270
	Dec	10,331,442		Dec	13,101,552		Dec	11,184,593
2001	Jan	11,293,260	2004	Jan	9,099,646	2007	Jan	10,765,522
	Feb	11,975,342		Feb	8,746,514		Feb	11,569,444
	Mar	10,319,789		Mar	8,171,269		Mar	11,923,432
	Apr	9,795,113		Apr	9,281,258		Apr	11,528,680
	May	11,500,762		May	13,947,633		May	13,308,215
	Jun	10,555,022		Jun	13,670,934		Jun	14,008,924
	Jul	11,434,761		Jul	12,439,933		Jul	13,398,747
	Aug	13,899,973		Aug	13,562,669		Aug	12,357,862
	Sep	12,570,944		Sep	13,227,059		Sep	11,850,666
	Oct	11,219,653		Oct	13,178,884		Oct	10,044,332
	Nov	8,381,912		Nov	10,967,396		Nov	11,351,544
	Dec	14,069,118		Dec	11,727,470		Dec	13,220,220

lanjutan

Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor	Tahun	Bulan	Vol Ekspor
2008	Jan	12,501,011	2011	Jan	10,512,098	2014	Jan	11,691,316
	Feb	10,469,722		Feb	10,939,355		Feb	12,555,915
	Mar	12,836,300		Mar	11,703,322		Mar	12,996,871
	Apr	14,334,269		Apr	11,200,264		Apr	12,498,277
	May	15,139,827		May	9,805,341		May	11,390,872
	Jun	14,318,006		Jun	10,673,513		Jun	12,659,869
	Jul	13,941,340		Jul	11,674,084		Jul	12,770,188
	Aug	12,369,925		Aug	9,735,955		Aug	13,707,646
	Sep	12,262,359		Sep	8,916,370		Sep	15,940,745
	Oct	9,140,695		Oct	12,347,912		Oct	15,045,225
	Nov	10,383,091		Nov	11,620,069		Nov	13,785,890
	Dec	11,847,453		Dec	12,515,395		Dec	14,168,276
2009	Jan	11,386,421	2012	Jan	11,161,599	2015	Jan	12,049,381
	Feb	11,468,241		Feb	12,121,629		Feb	12,669,313
	Mar	12,503,432		Mar	12,665,932		Mar	13,055,847
	Apr	10,047,482		Apr	11,119,931		Apr	13,990,548
	May	9,072,804		May	10,904,159		May	12,609,148
	Jun	9,690,976		Jun	12,154,823		Jun	13,479,629
	Jul	9,238,088		Jul	11,702,253		Jul	10,970,578
	Aug	10,514,853		Aug	9,080,438			
	Sep	8,679,472		Sep	12,584,720			
	Oct	12,444,562		Oct	12,304,484			
	Nov	9,587,409		Nov	11,132,683			
	Dec	10,203,127		Dec	10,845,102			
2010	Jan	8,829,746	2013	Jan	10,116,425			
	Feb	9,296,348		Feb	10,106,580			
	Mar	10,221,640		Mar	13,381,331			
	Apr	10,184,090		Apr	13,131,577			
	May	9,537,514		May	13,476,965			
	Jun	11,169,463		Jun	13,110,245			
	Jul	10,807,509		Jul	13,997,297			
	Aug	9,668,237		Aug	9,702,580			
	Sep	12,435,753		Sep	13,547,563			
	Oct	9,529,824		Oct	13,235,234			
	Nov	10,114,480		Nov	10,900,890			
	Dec	11,488,969		Dec	10,955,216			

Sumber: BPS

Lampiran 4. Output Program SAS untuk Model ARIMA (1,0,1) pada kelompok komoditi 302

Maximum Likelihood Estimation					
Parameter	Estimate	Standard Error	Approx t Value	Pr > t	Lag
MU	0.0003549	0.00001048	33.87	<.0001	0
MA1,1	0.74223	0.08273	8.97	<.0001	1
AR1,1	0.93670	0.04233	22.13	<.0001	1
Constant Estimate		0.000022			
Variance Estimate		1.27E-9			
Std Error Estimate		0.000036			
AIC		-2961.14			
SBC		-2951.77			
Number of Residuals		168			

Autocorrelation Check of Residuals									
To Lag	Chi-Square	Pr > DF	ChiSq	-----Autocorrelations-----					
6	2.64	4	0.6200	-0.035	0.023	0.023	0.087	-0.062	-0.038
12	11.04	10	0.3548	0.126	-0.032	-0.030	0.080	-0.038	0.144
18	15.58	16	0.4824	-0.036	-0.077	-0.116	-0.019	0.036	-0.044
24	20.80	22	0.5330	0.056	0.021	0.030	-0.024	-0.064	0.132
30	22.82	28	0.7418	-0.034	0.010	-0.051	0.053	-0.016	-0.055
36	31.17	34	0.6072	0.035	-0.077	0.010	-0.116	-0.128	0.045
42	33.60	40	0.7525	-0.016	-0.091	0.004	-0.010	-0.026	-0.041
48	37.70	46	0.8033	0.100	-0.012	-0.026	0.036	-0.067	-0.031

Tests for Normality				
Test	Statistic	Statistic	p Value	p Value
Shapiro-Wilk	W	0.98611	Pr < W	0.0939
Kolmogorov-Smirnov	D	0.04886	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.084695	Pr > W-Sq	0.1856
Anderson-Darling	A-Sq	0.60103	Pr > A-Sq	0.1195

Lampiran 5. Output Program SAS untuk Model ARIMA (2,0,0) (0,0,1)¹² tanpa deteksi outlier pada kelompok komoditi 303

Maximum Likelihood Estimation						
Parameter	Estimate	Standard Error	t Value	Pr > t	Approx Lag	
MU	0.24503	0.0012185	201.09	<.0001	0	
MA1,1	-0.20735	0.07803	-2.66	0.0079	12	
AR1,1	0.23638	0.07131	3.31	0.0009	1	
AR1,2	0.42755	0.07074	6.04	<.0001	2	
Constant Estimate			0.082347			
Variance Estimate			0.000021			
Std Error Estimate			0.004548			
AIC			-1330.25			
SBC			-1317.76			
Number of Residuals			168			

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.93	3	0.1772	-0.061	-0.056	0.130	0.000	0.042	0.055
12	14.58	9	0.1032	-0.149	0.035	0.061	-0.066	0.147	0.023
18	24.71	15	0.0539	0.069	0.133	0.045	0.027	0.053	0.161
24	27.66	21	0.1501	0.024	0.015	-0.030	-0.074	-0.016	0.087
30	34.56	27	0.1503	-0.025	-0.041	0.002	-0.024	0.156	-0.079

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.970768	Pr < W	0.0013	
Kolmogorov-Smirnov	D	0.075454	Pr > D	0.0199	
Cramer-von Mises	W-Sq	0.221822	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	1.37694	Pr > A-Sq	<0.0050	

Outlier Details				
Obs	Type	Estimate	Approx Chi-Square	Prob> ChiSq
89	Additive	-0.01507	23.54	<.0001
42	Additive	-0.01399	20.78	<.0001
60	Additive	-0.0098700	10.38	0.0013
62	Additive	-0.01318	18.86	<.0001
55	Additive	0.0097767	12.35	0.0004
120	Additive	-0.0096629	11.68	0.0006
71	Additive	-0.0091149	11.14	0.0008
130	Shift	-0.0047655	11.36	0.0008
14	Additive	0.0080158	9.76	0.0018
2	Additive	0.0099457	12.59	0.0004

Lampiran 6. Output Program SAS untuk Model ARIMA (2,0,0) (0,0,1)¹² dengan deteksi outlier pada kelompok komoditi 303

Maximum Likelihood Estimation							
Parameter	Standard		t Value	Pr > t	Approx Lag	Variable	Shift
	Estimate	Error					
MU	0.24513	0.0012823	191.16	<.0001	0	y	0
MA1,1	-0.28241	0.07861	-3.59	0.0003	12	y	0
AR1,1	0.33833	0.07520	4.50	<.0001	1	y	0
AR1,2	0.35728	0.07522	4.75	<.0001	2	y	0
NUM1	-0.01610	0.0035361	-4.55	<.0001	0	d1	0
NUM2	-0.0086895	0.0035500	-2.45	0.0144	0	d2	0
NUM3	-0.01191	0.0035467	-3.36	0.0008	0	d3	0
NUM4	0.0093885	0.0035461	2.65	0.0081	0	d4	0
Constant Estimate				0.074616			
Variance Estimate				0.000017			
Std Error Estimate				0.0041			
AIC				-1360.72			
SBC				-1335.73			
Number of Residuals				168			

Autocorrelation Check of Residuals									
To Lag	Chi-Square	Pr > DF	ChiSq	-----Autocorrelations-----					
6	7.61	3	0.0549	-0.063	-0.073	0.172	-0.016	0.058	0.040
12	15.93	9	0.0684	-0.090	0.056	-0.082	-0.088	0.141	0.021
18	22.22	15	0.1023	0.089	0.114	0.016	0.077	0.077	0.028
24	22.91	21	0.3489	-0.014	0.027	-0.016	0.002	0.016	0.045
30	24.42	27	0.6071	0.008	0.007	-0.019	0.000	0.082	-0.011

Tests for Normality					
Test	--Statistic--		----p Value----		
Shapiro-Wilk	W	0.983223	Pr < W	0.0403	
Kolmogorov-Smirnov	D	0.056731	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.152701	Pr > W-Sq	0.0224	
Anderson-Darling	A-Sq	0.866399	Pr > A-Sq	0.0256	

Lampiran 7. Output Program SAS untuk Model ARIMA (1,0,[1,10]) pada kelompok komoditi 306

Maximum Likelihood Estimation					
Parameter	Standard Estimate	Error	t Value	Approx Pr > t	Lag
MU	3344.8	53.83047	62.14	<.0001	0
MA1,1	0.45055	0.12673	3.56	0.0004	1
MA1,2	-0.17889	0.07220	-2.48	0.0132	10
AR1,1	0.76577	0.08822	8.68	<.0001	1
Constant Estimate		783.4685			
Variance Estimate		53557.98			
Std Error Estimate		231.426			
AIC		2310.712			
SBC		2323.208			
Number of Residuals		168			

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.97	3	0.2645	-0.007	-0.060	0.007	-0.073	0.031	-0.113
12	6.00	9	0.7402	0.003	0.053	-0.038	-0.030	0.058	-0.051
18	10.94	15	0.7568	0.083	0.053	0.097	-0.031	-0.078	-0.017
24	26.64	21	0.1831	0.062	-0.105	0.139	0.086	-0.090	0.174
30	34.54	27	0.1508	-0.086	-0.000	0.020	0.032	0.069	-0.158
36	45.41	33	0.0736	-0.181	0.001	0.102	0.077	0.024	0.045
42	49.98	39	0.1119	-0.050	-0.053	0.001	-0.088	-0.065	0.056
48	56.40	45	0.1186	0.111	-0.075	-0.013	0.021	0.088	0.038

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.982489	Pr < W	0.0325
Kolmogorov-Smirnov	D	0.061627	Pr > D	0.1191
Cramer-von Mises	W-Sq	0.105424	Pr > W-Sq	0.0961
Anderson-Darling	A-Sq	0.617577	Pr > A-Sq	0.1076

Lampiran 9. Syntax Program SAS untuk Model ARIMA (2,0,0) (0,0,1)¹² pada kelompok komoditi 303

```
data ekspor;
input y d1 d2 d3 d4;
datalines;
0.243696558 0 0 0 0
0.25295409 0 0 0 0
.
.
.1 0 0 0 0
.1 0 0 0 0
;
proc arima data=ekspor;
identify var=y crosscorr=(d1 d2 d3 d4);
estimate p=2 q=(12) input=(d1 d2 d3 d4) plot method=ml;
outlier maxnum=10 alpha=0.01;
forecast out= ramalan lead=31;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```


Lampiran 11. Syntax program Matlab untuk peramalan FFNN dan Hibrida ARIMA-NN pada kelompok komoditi 302

```

clear all; % close all old variables
[a1 b1]=uigetfile('*.txt','data_302');
ekspor=load(strcat(b1,a1),'-ascii');
y=ekspor(:,2); %variabel Y =ekspor perikanan
x1=ekspor(:,3);
x=[x1];
p=x'; t=y';
H=1;
for i=1:10
H=H+1
[pn,minp,maxp,tn,mint,maxt]=premnmx(p,t); %preprocessing -> [-1,1]
test.P=pn(:,1:168); test.T=tn(:,1:168); %data testing
ptr=pn(:,169:199); ttr=tn(:,169:199); %data training
target=t(:,169:199);
ttst=t(:,1:168);
ntr=size((ttr),2); %jml observasi data training
iu=size((ptr),1); %jml input unit
M=((iu+1)*H)+(H+1); %jumlah parameter
ntst=size((test.T),2); %jml observasi data testing
%membangun jaringan syaraf feedforward
net=newff(p,t,[H,1],{'logsig','purelin'},'trainlm');
net=init(net);
%melihat bobot-bobot awal input, lapisan, dan bias
net.IW{1,1}; %bobot input
net.b{1,1}; %bobot bias input
net.LW{2,1}; %bobot hidden
net.b{2,1}; %bobot bias input
bobot_input_hidden=net.IW{1,1} %bobot input
bobot_bias_hidden=net.b{1,1} %bobot bias input
bobot_hidden_output=net.LW{2,1} %bobot hidden
bobot_bias_output=net.b{2,1} %bobot bias input
%set max epoch, goal, learning rate, show step
net.trainParam.epochs=10000;
net.trainParam.goal=0.02;
net.trainParam.show=250;
net.trainParam.max_fail=inf;
%melakukan pembelajaran
[net,tr]=train(net,ptr,ttr,[],[],test);
%melihat bobot-bobot akhir input, lapisan, dan bias
bobotakhir_input_hidden=net.IW{1,1} %bobot input akhir
bobotakhir_bias_hidden=net.b{1,1} %bobot bias input akhir
bobotakhir_hidden_output=net.LW{2,1} %bobot hidden akhir
bobotakhir_bias_output=net.b{2,1} %bobot bias input akhir
%-----
%Untuk mendapatkan nilai taksiran data training
an=sim(net,ptr);
a=postmnmx(an,mint,maxt);
e=target-a;
%evaluasi output jaringan (data pelatihan dengan target)

```

```

[m,b,r]=postreg(a,target);
%perhitungan kriteria in-sample dan out-sample
disp 'r'
disp(r);
r2=r*r;
disp 'r2'
disp(r2);
MSE=mse(e);
disp 'MSE'
disp(MSE);
AIC=(ntr*log(MSE))+(2*M);
disp 'AIC'
disp(AIC);
SBC=(ntr*log(MSE))+(M*log(ntr));
disp 'SBC'
disp(SBC);
RMSE_in=sqrt(MSE)
disp 'RMSE'
disp(RMSE_in);
%-----
%Untuk mendapatkan nilai taksiran data testing
anew=sim(net,test.P);
atst=postmnmx(anew,mint,maxt);
residual_test=ttst-atst;
[m,b,rh]=postreg(atst,ttst);
n2=length(ttst);
disp 'r testing'
disp(rh);
rh2=rh*rh;
disp 'r2 testing'
disp(rh2);
MSE_tst=mse(residual_test);
disp 'MSE testing'
disp(MSE_tst);
AIC_tst=(ntst*log(MSE_tst))+(2*M);
disp 'AIC testing'
disp(AIC_tst);
SBC_tst=(ntst*log(MSE_tst))+(M*log(ntst));
disp 'SBC testing'
disp(SBC_tst);
RMSE_test=sqrt(MSE_tst)
disp 'RMSE testing'
disp(RMSE_test);
MAPE_test=(sum(abs((residual_test)./ttst))*100)/n2
disp 'MAPE testing'
disp(MAPE_test);
disp 'a'
disp(a);
disp 'atst'
disp(atst);
end;

```

Lampiran 12. Syntax program Matlab untuk peramalan FFNN dan Hibrida ARIMA-NN pada kelompok komoditi 303

```

clear all; % close all old variables
[a1 b1]=uigetfile('*.txt','3data_303');
ekspor=load(strcat(b1,a1),'-ascii');
y=ekspor(:,2); %variabel Y =ekspor perikanan
x1=ekspor(:,3:4);
x=[x1];
p=x'; t=y';
H=0;
for i=1:10
H=H+1
[pn,minp,maxp,tn,mint,maxt]=premnmx(p,t); %preprocessing -> [-1,1]
test.P=pn(:,1:168); test.T=tn(:,1:168); %data testing
ptr=pn(:,169:199); ttr=tn(:,169:199); %data training
target=t(:,169:199);
ttst=t(:,1:168);
ntr=size((ttr),2); %jml observasi data training
iu=size((ptr),1); %jml input unit
M=((iu+1)*H)+(H+1); %jumlah parameter
ntst=size((test.T),2); %jml observasi data testing
%membangun jaringan syaraf feedforward
net=newff(p,t,[H,1],{'logsig', 'purelin'}, 'trainlm');
net=init(net);
%melihat bobot-bobot awal input, lapisan, dan bias
net.IW{1,1}; %bobot input
net.b{1,1}; %bobot bias input
net.LW{2,1}; %bobot hidden
net.b{2,1}; %bobot bias input
bobot_input_hidden=net.IW{1,1} %bobot input
bobot_bias_hidden=net.b{1,1} %bobot bias input
bobot_hidden_output=net.LW{2,1} %bobot hidden
bobot_bias_output=net.b{2,1} %bobot bias input
%set max epoch, goal, learning rate, show step
net.trainParam.epochs=50000;
net.trainParam.goal=0.02;
net.trainParam.show=250;
net.trainParam.max_fail=inf;
%melakukan pembelajaran
[net,tr]=train(net,ptr,ttr,[],[],test);
%melihat bobot-bobot akhir input, lapisan, dan bias
bobotakhir_input_hidden=net.IW{1,1} %bobot input akhir
bobotakhir_bias_hidden=net.b{1,1} %bobot bias input akhir
bobotakhir_hidden_output=net.LW{2,1} %bobot hidden akhir
bobotakhir_bias_output=net.b{2,1} %bobot bias input akhir
%-----
%Untuk mendapatkan nilai taksiran data training
an=sim(net,ptr);
a=postmnmx(an,mint,maxt);
e=target-a;
%evaluasi output jaringan (data pelatihan dengan target)

```



```

[m,b,r]=postreg(a,target);
%perhitungan kriteria in-sample dan out-sample
disp 'r'
disp(r);
r2=r*r;
disp 'r2'
disp(r2);
MSE=mse(e);
disp 'MSE'
disp(MSE);
AIC=(ntr*log(MSE))+(2*M);
disp 'AIC'
disp(AIC);
SBC=(ntr*log(MSE))+(M*log(ntr));
disp 'SBC'
disp(SBC);
RMSE_in=sqrt(MSE)
disp 'RMSE'
disp(RMSE_in);
%-----
%Untuk mendapatkan nilai taksiran data testing
anew=sim(net,test.P);
atst=postmnmx(anew,mint,maxt);
residual_test=ttst-atst;
[m,b,rh]=postreg(atst,ttst);
n2=length(ttst);
disp 'r testing'
disp(rh);
rh2=rh*rh;
disp 'r2 testing'
disp(rh2);
MSE_tst=mse(residual_test);
disp 'MSE testing'
disp(MSE_tst);
AIC_tst=(ntst*log(MSE_tst))+(2*M);
disp 'AIC testing'
disp(AIC_tst);
SBC_tst=(ntst*log(MSE_tst))+(M*log(ntst));
disp 'SBC testing'
disp(SBC_tst);
RMSE_test=sqrt(MSE_tst)
disp 'RMSE testing'
disp(RMSE_test);
MAPE_test=(sum(abs((residual_test)./ttst))/n2)*100
disp 'MAPE testing'
disp(MAPE_test);
disp 'a'
disp(a);
disp 'atst'
disp(atst);
end;

```

Lampiran 13. Syntax program Matlab untuk peramalan FFNN dan Hibrida ARIMA-NN pada kelompok komoditi 306

```

clear all; % close all old variables
[a1 b1]=uigetfile('*.txt','data_residual_306');
ekspor=load(strcat(b1,a1),'-ascii');
y=ekspor(:,2); %variabel Y =ekspor perikanan
x1=ekspor(:,3);
x=[x1];
p=x'; t=y';
H=3;
for i=1
H=H+1
[pn,minp,maxp,tn,mint,maxt]=premnmx(p,t); %preprocessing -> [-1,1]
test.P=pn(:,1:168); test.T=tn(:,1:168); %data testing
ptr=pn(:,169:199); ttr=tn(:,169:199); %data training
target=t(:,169:199);
ttst=t(:,1:168);
ntr=size((ttr),2); %jml observasi data training
iu=size((ptr),1); %jml input unit
M=((iu+1)*H)+(H+1); %jumlah parameter
ntst=size((test.T),2); %jml observasi data testing
%membangun jaringan syaraf feedforward
net=newff(p,t,[H,1],{'logsig', 'purelin'}, 'trainlm');
net=init(net);
%melihat bobot-bobot awal input, lapisan, dan bias
net.IW{1,1}; %bobot input
net.b{1,1}; %bobot bias input
net.LW{2,1}; %bobot hidden
net.b{2,1}; %bobot bias input
bobot_input_hidden=net.IW{1,1} %bobot input
bobot_bias_hidden=net.b{1,1} %bobot bias input
bobot_hidden_output=net.LW{2,1} %bobot hidden
bobot_bias_output=net.b{2,1} %bobot bias input
%set max epoch, goal, learning rate, show step
net.trainParam.epochs=50000;
net.trainParam.goal=0.02;
net.trainParam.show=250;
net.trainParam.max_fail=inf;
%melakukan pembelajaran
[net,tr]=train(net,ptr,ttr,[],[],test);
%melihat bobot-bobot akhir input, lapisan, dan bias
bobotakhir_input_hidden=net.IW{1,1} %bobot input akhir
bobotakhir_bias_hidden=net.b{1,1} %bobot bias input akhir
bobotakhir_hidden_output=net.LW{2,1} %bobot hidden akhir
bobotakhir_bias_output=net.b{2,1} %bobot bias input akhir
%-----
%Untuk mendapatkan nilai taksiran data training
an=sim(net,ptr);
a=postmnmx(an,mint,maxt);
e=target-a;
%evaluasi output jaringan (data pelatihan dengan target)

```

```

[m,b,r]=postreg(a,target);
%perhitungan kriteria in-sample dan out-sample
disp 'r'
disp(r);
r2=r*r;
disp 'r2'
disp(r2);
MSE=mse(e);
disp 'MSE'
disp(MSE);
AIC=(ntr*log(MSE))+(2*M);
disp 'AIC'
disp(AIC);
SBC=(ntr*log(MSE))+(M*log(ntr));
disp 'SBC'
disp(SBC);
RMSE_in=sqrt(MSE)
disp 'RMSE'
disp(RMSE_in);
%-----
%Untuk mendapatkan nilai taksiran data testing
anew=sim(net,test.P);
atst=postmnmx(anew,mint,maxt);
residual_test=ttst-atst;
[m,b,rh]=postreg(atst,ttst);
n2=length(ttst);
disp 'r testing'
disp(rh);
rh2=rh*rh;
disp 'r2 testing'
disp(rh2);
MSE_tst=mse(residual_test);
disp 'MSE testing'
disp(MSE_tst);
AIC_tst=(ntst*log(MSE_tst))+(2*M);
disp 'AIC testing'
disp(AIC_tst);
SBC_tst=(ntst*log(MSE_tst))+(M*log(ntst));
disp 'SBC testing'
disp(SBC_tst);
RMSE_test=sqrt(MSE_tst)
disp 'RMSE testing'
disp(RMSE_test);
MAPE_test=(sum(abs((residual_test)./ttst))/n2)*100
disp 'MAPE testing'
disp(MAPE_test);
RAMALAN=a
disp 'RAMALAN'
disp(a);
end;

```

Lampiran 14. Perbandingan Hasil Peramalan pada Kelompok Komoditi 302

Bulan	Aktual	ARIMA	FFNN	Hibrida ARIMA-NN	Chen-1	Chen-2	Yu	Lee	Cheng
Jan	5723638	7398282	7304190	7398282	9925000	7763542	8512840	10636779	3853440
Feb	16525978	7430989	7146951	7430989	9362500	7472414	8851034	13645815	6301758
Mar	5881833	7461875	8499211	7461875	5500000	5500000	5500000	5500000	11012989
Apr	7849281	7490904	7154098	7490904	9362500	7472414	8851034	13645815	6380856
May	7012080	7518040	7733026	7518040	9925000	7763542	8512840	10636779	7778081
Jun	6420241	7544081	7307049	7544081	9925000	7763542	8512840	10636779	7359480
Jul	7645293	7568175	7195552	7568175	10225000	7300000	8332460	13582780	6537931
Aug	5386924	7591129	7592939	7591129	9925000	7763542	8512840	10636779	7676087
Sep	5451201	7612508	7134086	7612508	9362500	7472414	8851034	13645815	6133401
Oct	6366876	7632711	7136944	7632711	9362500	7472414	8851034	13645815	6165540
Nov	6605140	7651725	7189834	7651725	10225000	7300000	8332460	13582780	6511249
Dec	17202909	7669536	7219853	7669536	10225000	7300000	8332460	13582780	6630381
Jan	5225220	7686556	8462046	7686556	5500000	5500000	5500000	5500000	11351455
Feb	4399982	7702350	7128368	7702350	9362500	7472414	8851034	13645815	6052549
Mar	5863288	7716907	7078337	7716907	6500000	6000000	6300000	6385048	5092848
Apr	8574756	7731075	7152668	7731075	9362500	7472414	8851034	13645815	6371583
May	6032102	7743989	8310524	7743989	10027778	8694737	9732880	14755598	8623692
Jun	5390680	7756503	7162675	7756503	10225000	7300000	8332460	13582780	6343862
Jul	5060850	7767748	7134086	7767748	9362500	7472414	8851034	13645815	6135279
Aug	4439208	7778584	7121221	7778584	9362500	7472414	8851034	13645815	5970364
Sep	5311463	7789008	7081196	7789008	6500000	6000000	6300000	6385048	5112461
Oct	5821206	7798581	7131227	7798581	9362500	7472414	8851034	13645815	6095671
Nov	6003223	7807300	7151239	7807300	9362500	7472414	8851034	13645815	6350542
Dec	5940900	7815596	7161245	7815596	10225000	7300000	8332460	13582780	6329422
Jan	5338378	7823468	7156957	7823468	9362500	7472414	8851034	13645815	6410389
Feb	4616353	7830914	7132656	7830914	9362500	7472414	8851034	13645815	6109128
Mar	5736042	7837931	7096920	7837931	6500000	6000000	6300000	6385048	5201034
Apr	6079204	7844518	7146951	7844518	9362500	7472414	8851034	13645815	6307960
May	5905763	7850673	7165534	7850673	10225000	7300000	8332460	13582780	6367413
Jun	5476311	7856396	7155527	7856396	9362500	7472414	8851034	13645815	6392821
Jul	4609800	7861683	7136944	7861683	9362500	7472414	8851034	13645815	6178095

Lampiran 15. Perbandingan Hasil Peramalan pada Kelompok Komoditi 303

Bulan	Aktual	ARIMA	FFNN	Hibrida ARIMA-NN	Chen-1	Chen-2	Yu	Lee	Cheng
Jan	28928626	31426059	35978905	31426058	39062500	33906250	39437500	34375000	32828608
Feb	21682130	32716336	34566692	32716335	40937500	31310976	38249129	31585366	30647146
Mar	35329236	25464090	27763772	25464089	45892857	23301887	30644654	23301887	19086860
Apr	39919307	26118622	29570797	26118620	40937500	31310976	38249129	31585366	30647146
May	52326182	33047826	34035214	33047825	39062500	33906250	39437500	34375000	32828608
Jun	36336444	36411880	36404088	36411878	35125000	28750000	39732143	30625000	27410714
Jul	35383813	34660495	36571123	34660493	39062500	33906250	39437500	34375000	32828608
Aug	26544345	27955231	33412625	27955230	40937500	31310976	38249129	31585366	30647146
Sep	38523826	31471176	31165232	31471174	40937500	31310976	38249129	31585366	30647146
Oct	42202998	29257437	31727080	29257435	39062500	33906250	39437500	34375000	32828608
Nov	41555557	33527730	35022244	33527729	39062500	33906250	39437500	34375000	32828608
Dec	27074581	36677445	35584093	36677444	39062500	33906250	39437500	34375000	32828608
Jan	36547415	27955231	32896332	27955230	40937500	31310976	38249129	31585366	30647146
Feb	25936982	23180174	31393008	23180172	39062500	33906250	39437500	34375000	32828608
Mar	38715329	30104717	31317083	30104715	40937500	31310976	38249129	31585366	30647146
Apr	24884503	30890107	31605599	30890105	39062500	33906250	39437500	34375000	32828608
May	40145021	31697819	31651155	31697817	45892857	23301887	30644654	23301887	19086860
Jun	33804795	26527609	31666340	26527607	39062500	33906250	39437500	34375000	32828608
Jul	36495212	30757676	33944103	30757675	40937500	31310976	38249129	31585366	30647146
Aug	29321144	28679781	33048183	28679779	39062500	33906250	39437500	34375000	32828608
Sep	42358027	30018800	32137077	30018798	40937500	31310976	38249129	31585366	30647146
Oct	43408103	32763470	33200034	32763468	39062500	33906250	39437500	34375000	32828608
Nov	34357559	36464825	35842239	36464824	39062500	33906250	39437500	34375000	32828608
Dec	29369002	28517023	34718543	28517021	40937500	31310976	38249129	31585366	30647146
Jan	19372024	29975942	31590414	29975940	40937500	31310976	38249129	31585366	30647146
Feb	13590540	23212575	27156368	23212574	45892857	23301887	30644654	23301887	19086860
Mar	15843933	18151391	21082333	18151389	57946429	16818182	23099559	16818182	9170854
Apr	12533691	14193212	19563824	14193210	45892857	23301887	30644654	23301887	19086860
May	14303882	16170422	19077901	16170420	57946429	16818182	23099559	16818182	9170854
Jun	13737613	15424342	18379387	15424341	45892857	23301887	30644654	23301887	19086860
Jul	13887808	15845962	18926050	15845960	57946429	16818182	23099559	16818182	9170854

Lampiran 16. Perbandingan Hasil Peramalan pada Kelompok Komoditi 306

Bulan	Aktual	ARIMA	NN		WFTS				
			FFNN	Hibrida ARIMA-NN	Chen-1	Chen-2	Yu	Lee	Cheng
Jan	10116425	11484905	19751646	10098954	11500000	11565789	11584211	12080354	11553030
Feb	10106580	10916351	19462836	10093177	11550000	11812500	11849265	12323693	11953704
Mar	13381331	10643055	19459342	13364565	11550000	11812500	11849265	12323693	11953704
Apr	13131577	11801232	20756659	13093638	11550000	11812500	11849265	12323693	11953704
May	13476965	12219173	20657671	13447492	11550000	11812500	11849265	12323693	11953704
Jun	13110245	12016491	20795089	13081300	24917396	12964286	12888095	12380440	12967391
Jul	13997297	12515021	20649519	13969214	11250000	11000000	10735294	9970653	10989130
Aug	9702580	12857318	21001216	9672489	24917396	12964286	12888095	12380440	12967391
Sep	13547563	11427276	19298633	13544690	11550000	11812500	11849265	12323693	11953704
Oct	13235234	11972604	20823038	13201199	11400000	11281250	11055147	9196296	11403846
Nov	10900890	12037457	20699595	10871848	11400000	11281250	11055147	9196296	11403846
Dec	10955216	11414968	19773773	10940183	12194444	11500000	11454762	11177941	11261111
Jan	11691316	11675542	19795899	11672281	11634615	12125000	11595238	10543896	12370690
Feb	12555915	11826447	20087038	12534004	11634615	12125000	11595238	10543896	12370690
Mar	12996871	12162963	20429418	12970815	11750000	11694444	11831871	11797682	11700000
Apr	12498277	12444025	20605266	12471689	18352500	11650000	11578571	9834372	11831395
May	11390872	12475352	20407292	11368744	11634615	12125000	11595238	10543896	12370690
Jun	12659869	11421137	19968254	12644398	11634615	12125000	11595238	10543896	12370690
Jul	12770188	12128639	20471342	12741118	24917396	12964286	12888095	12380440	12967391
Aug	13707646	12381091	20514431	13682141	13750000	13750000	13750000	13750000	13750000
Sep	15940745	12423216	20885925	15911466	14083333	14083333	14083333	14107143	14125000
Oct	15045225	13220705	21770988	15004322	24917396	12964286	12888095	12380440	12967391
Nov	13785890	13425632	21416963	13754202	10750000	11083333	10683333	10317515	11000000
Dec	14168276	13249146	20917368	14144479	11750000	11694444	11831871	11797682	11700000
Jan	12049381	13298540	21068760	12022526	11634615	12125000	11595238	10543896	12370690
Feb	12669313	12524578	20229114	12654588	11550000	11812500	11849265	12323693	11953704
Mar	13055847	12181179	20474836	13033204	24917396	12964286	12888095	12380440	12967391
Apr	13990548	12497655	20628557	13963734	11634615	12125000	11595238	10543896	12370690
May	12609148	12848178	20998887	12578993	11550000	11812500	11849265	12323693	11953704
Jun	13479629	12684126	20451545	13459168	11550000	11812500	11849265	12323693	11953704
Jul	10970578	13195867	20796254	10944298	11400000	11281250	11055147	9196296	11403846

Lampiran 17. Perbandingan Kinerja Peramalan masing-masing kelompok komoditi

Metode	RMSE	MAPE
Kelompok Komoditi 302		
ARIMA	3,120,105	37.05731
FFNN	3,004,962	31.74057
Hibrida ARIMA-NN	3,120,105	37.05731
Chen-1	3,865,959	56.92633
Chen-2	2,956,469	30.01711
Yu	3,398,129	44.76966
Lee	5,811,554	75.9006
Cheng	3,218,867	26.33703
Kelompok Komoditi 303		
ARIMA	8,046,663	21.504644
FFNN	8,035,619	26.986429
Hibrida ARIMA-NN	8,046,663	21.504642
Chen-1	18,984,913	74.7722
Chen-2	8,460,972	27.0753
Yu	10,070,010	38.7660
Lee	7,186,581	27.0256
Cheng	8,915,778	26.9326
Kelompok Komoditi 306		
ARIMA	1,473,676	9.6704
FFNN	7,896,012	63.2542
Hibrida ARIMA-NN	1,465,931	9.6016
Chen-1	5,252,273	26.1894
Chen-2	1,518,630	9.6594
Yu	1,586,039	9.8908
Lee	1,993,578	13.2309
Cheng	1,487,133	9.4150



DAFTAR PUSTAKA

Afxentiou, P., Serletis, A., (2000), "Output Growth and Variability of Export and Import Growth: International Evidence from Granger Causality Tests," *The Developing Economies* Vol. XXXVIII, Issue 2, pp. 141-163.

Alteren, G., Tudoran, A.A., (2015), "Enhancing Export Performance: Betting on Customer Orientation, Behavioral Commitment and Communication," *International Business Review*, Vol. 53, pp. 610-627.

Allen, P.G., (1994), "Economic Forecasting in Agriculture," *International Journal of Forecasting*, Vol. 10, pp. 81-135.

Al Mamun, K.A., Nath, H.K., (2005), "Export-Led Growth in Bangladesh: A Time series Analysis," *Applied Economic Letters*, Vol. 12, pp. 361-364.

Arumugam, P., Anithakumari, V., (2013), " Fuzzy Time series Method for Forecasting Taiwan Export Data", *International Journal of Engineering Trends and Technology (IJETT)*, Vol. 4, Issue 8, pp. 3342-3347.

Awokuse, T.O., (2007), "Causality Between Exports, Imports, and Economic Growth: Evidence from Transition Economies," *Economic Letters*, Vol. 94, pp. 389-395.

Bai, Q., Zhang, S.T., Wang, W.L., Wang, Z.J., (2015), "Variansce of Graphite Import-Export Volume and Price in China for 2003-2012: A Deret waktu Analysis," *Resources Policy*, Vol. 44, pp. 65-70.

Barus, J.H., (2013), "*Analisis Peramalan Ekspor Indonesia Pasca Krisis Keuangan Eropa dan Global Tahun 2008 dengan Metode Dekomposisi*," Paper, USU, Medan.

Bowerman, B.I. and O'Connell, R.T., (1987), *Time series Forecasting, Unified Concepts and Computer Implementation*, Second Edition, Duxbury Press, Boston.

Box, G., Jenkins, M.G dan Reinsel, G., (1994), *Time series Analysis: Forecasting & Control*, 2nd ed, Prentice Hall.

- Chang, P-C., Wang, Y-W., Liu, C-H., (2007), "The Development of a Weighted Evolving *Fuzzy Neural Network* for PCB Sales Forecasting," *Expert Systems with Applications*, Vol. 32, pp. 86-96.
- Chen, S-M., (1996), "Forecasting Enrollments based on *Fuzzy Time series*," *Fuzzy Sets and Systems*, Vol. 81, pp. 311-319.
- Chen, S-M., (2002), "Forecasting Enrollments based on High-Order *Fuzzy Time series*", *Cybern. Syst. Int.*, Vol. 33, pp. 1-16.
- Chen, S-M., Chang, Y-C., (2011), "Weighted *Fuzzy Rule Interpolation* Based on GA-Based Weight-Learning Techniques," *IEEE Transaction on Fuzzy System*, Vol. 19, pp. 729-744.
- Cheng, C-H., Chen, T-L., Teoh, H.J., Chiang, C-H., (2008), "Fuzzy *Time series* based on Adaptive Expectation Model for TAIEX Forecasting," *Expert Systems with Applications*, Vol. 34, pp. 1126-1132.
- Co, H.C., Boosarawongse, R., (2007), "Forecasting Thailand's Rice Export: Statistical Techniques vs. Artificial *Neural Networks*," *Computers & Industrial Engineering*, Vol. 53, pp. 610-627.
- Coulibaly, P., Anctil, F., Bobee, B., (2000), "Daily Reservoir Inflow Forecasting Using Artificial Neural Networks with Stopped *Training Approach*", *Journal of Hydrology*, Vol. 230, pp. 244-257.
- Dasgupta, N., (2009), "Examining The Long Run Effects of Export, Import, and FDI Inflows on The FDI Outflows from India: A Causality Analysis," *Journal of International Business and Economy*, Vol. 10, Issue 1, pp. 65-88.
- Fausett, L., (1994), *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, Prentice Hall.
- Gaxiola, F., Melin, P., Valdez, F., Castillo, O., (2014), "Interval Type-2 *Fuzzy Weight Adjustment* for Backpropagation Neural Networks in *Time series Prediction*", *Information Sciences*, Vol. 260, pp. 1-14.
- Gaxiola, F., Melin, P., Valdez, F., Castillo, O., (2015), "Generalized Type-2 *Fuzzy Weight Adjustment* for Backpropagation Neural Networks in *Time series Prediction*", *Information Sciences*, Vol. 325, pp. 159-174.
- Geem, Z.W., Roper, W.E., (2009), "Energy Demand Estimation of South Korea using Artificial *Neural Network*," *Energy Policy*, Vol. 37, pp. 4049-4054.

Haykin, S., (1998), *Neural Networks: A Comprehensive Foundations*, Prentice Hall.

Hornik, K., Stinchcombe, M., White, H., (1989), "Multilayer Feedforward Networks are Universal Approximate," *Neural Networks*, Vol. 2, pp. 359-366.

Huarng, K., Yu, T.H-K., (2005), "The Application of Neural Networks to Forecast *Fuzzy Time series* ". *Physica A*, Vol. 363, pp. 481-491.

Jeong, K., Koo, C., Hong, T., (2014), "An Estimation Model for Determining The Annual Energy Cost Budget in Educational Facilities using SARIMA and ANN," *Energy*, pp. 1-9.

Kaastra, I., Boyd, M., (1996), "Designing A *Neural Network* for Forecasting Financial and Economic *Time series*," *Neurocomputing*, Vol. 10, pp. 215-236.

Kajitani, Y., (1999), *Forecasting Time series with Neural Nets*, Master Thesis, Faculty of Graduate Studies The University of Western Ontario, Ontario.

Kargbo, J.M., (2007), "Forecasting Agricultural Exports and Imports in South Africa, *Applied Economics*, Vol. 39, Issue 16, pp. 2069-2084.

Kaashoek, J.F. and Van Dijk, H.K., (2002), "Neural Networks Pruning Applied to Real Exchange Rate Analysis", *Journal of Forecasting*, Vol. 21, Issue 8, pp. 559-577.

Khashei, M., Hejazi, S.R., Bijari, M., (2008), "A New Hybrid Artificial *Neural Networks* and *Fuzzy Regression Model* for *Time series* Forecasting," *Fuzzy Sets and Systems*, Vol. 159, pp. 769-786.

Koutroumanidis, T., Ioannou, K., Arabatzis, G., (2009), "Predicting Fuelwood Prices in Greece with The Use of ARIMA Models, Artificial *Neural Networks* and A Hybrid ARIMA-ANN Model ," *Energy Policy*, Vol. 37, pp. 3627-3634.

Kuan, C-M., Liu, T., (1995), "Forecasting Exchange Rates Using Feedforward and Recurrent Neural Networks", *Journal of Applied Econometrics*, Vol. 10, pp. 347-364.

Kunst, R.M., Marin, D., (1989), "On Export and Productivity: A Causal Analysis," *Review of Economics and Statistics*, Vol. 71, pp. 699-703.

- Kusumadewi, F., (2014), *Peramalan Harga Emas Menggunakan Feedforward neural Network dengan Algoritma Backpropagation*, Skripsi, UNY, Yogyakarta.
- Law, R. (1999), "Back-Propagation Learning in Improving The Accuracy of Neural Network- Based Tourism Demand Forecasting", *Tourism Management*, Vol. 21, pp. 331-340.
- Lee, L-W., Wang, L-H., Chen, S-M., and Leu, Y-H., (2006), "Handling Forecasting Problems Based on Two-Factors High-Order *Fuzzy Time series*", *IEEE Transactions on Fuzzy Systems*, Vol. 14, pp. 468-477.
- Lee, L-W., Wang, L-H., and Chen, S-M., (2008), "Temperature Prediction and TAIEX Forecasting based on High-Order *Fuzzy Logical Relationships* and Genetic Simulated Annealing Techniques", *Expert Systems with Applications*, Vol. 34, pp. 328-336.
- Lee, Y-S., Lius, W-Y., (2014), "Forecasting Value of Agricultural Imports using A Novel Two-Stage Hybrid Model," *Computers & Electronics in Agriculture*, Vol. 104, pp. 71-83.
- Lee, M.H., Suhartono, (2012), "A Weighted *Fuzzy Time series* Model for Forecasting Seasonal Data", *Journal of Quality Measurement and Analysis*, Vol. 8, Issue 1, pp. 85-95.
- Lusia, D.A., (2013), *Peramalan Inflasi dengan Metode Weighted Fuzzy Time series*, Skripsi, ITS, Surabaya.
- Mahadevan, R., Suardi, S., (2011), "The Effects of Uncertainty Dynamics on Exports, Imports, and Productivity Growth," *Journal of Asian Economics*, Vol. 22, pp. 174-188.
- Mankiw, N.G., (2009), "*Principles of Macroeconomics*," Edisi kelima, South-Western Cengage Learning, Mason.
- Makridakis, S., Wheelwright, S., dan Hyndman, R.J., (1998), *Forecasting: Methods and Applications* (3rd ed), Wiley: New York.
- Mehmood, S., (2012), "Forecasting Pakistan's Exports to SAARC: An Application of Univariate ARIMA Model", *Journal of Contemporary Issues in Bussiness Research*, Vol. 1, Issue 3, pp. 96-110.

Mishra, A.K., Desai, V.R., (2006), "Drought Forecasting Using Feed-Forward Recursive Neural Network," *Ecological Modelling*, Vol. 198, pp. 127-138.

Nuraeni, A., (2009), *Feed Forward Neural Network untuk Small Area Estimation pada Kasus Kemiskinan*, Tesis, ITS, Surabaya.

Paul, R.K., Panwar, S., Sarkar, S.K, Kumar, A., Singh, K.N., Farooqi, S., Choudhary, K., (2013), "Modelling and Forecasting of Meat Exports from India", *Agricultural Economics Research Review*, Vol. 26, pp. 249-255.

Priestley, M. B., (1988), *Non-Linear and Non Stationary Time series Analysis*, Chapman and Hall, London.

Putro, A.W., (2015), *Model Runtun Waktu Fuzzy Terbobot untuk Peramalan Jumlah Uang Beredar di Indonesia*, Skripsi, UNS, Semarang.

Reuter, U., Moller, B., (2010), "Artificial Neural Networks for Forecasting of Fuzzy Time series," *Computer-Aided Civil and Infrastructure Engineering*, Vol. 25, pp. 363-374.

Rokimah, N.J., (2012), *Pendekatan Fungsi Transfer Multi Input dan Artificial Neural Network untuk Meramalkan Inflasi Jawa Timur*, Tesis, ITS, Surabaya.

Ruslan, R., Harahap, A.S., Sembiring, P., (2013), "Peramalan Nilai Ekspor di Propinsi Sumatera Utara dengan Metode ARIMA Box-Jenkins", *Saintia Matematika*, Vol. 1, Issue 6, pp. 579-589.

Sen, B.B., Sabur, S.A., Islam, T., Alam, K., (2015), "Forecasting The Quantity of Shrimp and Dry Fish Export from Bangladesh", *Journal of Economics and Sustainable Development*, Vol.6, Issue 7, pp. 52-58.

Shamseldin, A.Y., Nasr, A.E., O'Connor, K.M., (2002), "Comparison of Different Forms of the Multilayer Feed-Forward Neural Network Method Used for River Flow Forecasting," *Hydrology and Earth System Sciences Discussions, Copernicus Publications*, Vol. 6, Issue 4, pp. 671-684.

Singhal, D., Swarup, K.S., (2011), "Electricity Price Forecasting using Artificial Neural Networks," *Electrical Power and Energy Systems*, Vol. 33, pp. 550-555.

Song, Q., and Chissom, B.S., (1993), "Forecasting Enrollments with Fuzzy Time series – Part I," *Fuzzy Sets and Systems*, Vol.54, pp. 1-9.

- Stoevsky, G., (2009), "Economic Forecasting of Bulgaria's Export and Import Flows," *Discussion Papers*, Bulgarian National Bank.
- Sukirno, S., (2006), "*Makroekonomi Teori Pengantar*," Edisi ketiga, PT. Raja Grafindo, Jakarta.
- Suryono, H., (2009), *Pemodelan Auto regressive Integrated Moving Average With Exogenous Factor-Neural network (ARIMAX-NN) pada Data Inflasi Indonesia*, Tesis, ITS, Surabaya.
- Susanto, R.T., (2009), *Hybrid Model ARIMA dan Neural Network pada Peramalan Kunjungan Wisatawan ke Bali*, Tesis, ITS, Surabaya.
- Syah, M.F., (2009), *Analisis Hubungan Produk Domestik Bruto, Ekspor, dan Impor dengan Menggunakan Pendekatan Vector Autoregression (VAR)*, Tesis, ITS, Surabaya.
- Tahir, A., (2014), "Forecasting Citrus Exports in Pakistan", *Pakistan Journal of Agricultural Research*, Vol.27, Issue 1, pp. 64-68.
- Tang, Z., Fishwick, P.A., (1993), "Feed-Forward Neural Nets as Models for Time series Forecasting," *ORSA Journal of Computing*, Vol. 5, Issue 4, pp. 374-385.
- Thomson, G.F., (1994), "A Forecasting Model of New Zealand's Lamb Exports", *Research Report no.223*, Lincoln University, Canterbury.
- Tong, H., (1983), *Threshold Models in Non-linear Time series Analysis*, 1st Ed., Springer-Verlag, New York.
- Triyanto, A.G., (2012), *Model Peramalan Hibrida ARIMA-NN pada Data Ekspor Indonesia*, Tesis, ITS, Surabaya.
- Tsai, C.C., and Wu, S.J., (1999), "A Study for Second Order Modelling of Fuzzy Time series," *IEEE International Fuzzy Systems Conference*, Proceedings.
- Wang, C. C. (2011). "A Comparison Study between Fuzzy Time series Model and ARIMA Model for Forecasting Taiwan Export", *Expert Systems with Applications*, Vol. 38, pp. 9296-9304.
- Wang, F., Chang, K. dan Tzeng, C. (2011), "Using Adaptive Network-based Fuzzy Inference System to Forecast Automobile Sales", *Expert Systems with Applications*, Vol. 38, pp. 10587-10593.

Watada, J., (1992), "Fuzzy Time series Analysis and Forecasting of Sales Volume," *Fuzzy Regression Analysis*, pp. 211-227.

Wei, W. W. S. (2006). *Time series Analysis Univariate and Multivariate Methods*, 2nd Edition. Addison Wesley Publishing Company Inc., New York.

Wibawa, A.P., Soelaiman, R., (2007), "Analisis Efektifitas Metode Hibrida Neural Networks dan Fuzzy Logic untuk Peramalan Valuta Asing", *Prosiding Seminar Nasional Manajemen Teknologi IV*, ITS, Surabaya.


Wienarti, I., (2011), *Peramalan (Forecasting) Nilai Ekspor Jawa Tengah menurut Komoditi dengan Metode Exponential Smoothing Bulan Desember 2009 sampai Juni 2010*, Skripsi, UNS, Semarang.

Yao, J., Tan, C.L., (2000), "A Case Study on Using Neural Networks to Perform Technical Forecasting of Forex," *Neurocomputing*, Vol. 34, pp. 79-98.

Yu, H-K., (2005), "Weighted Fuzzy Time series Models for TAIEX Forecasting". *Physica A*, Vol. 349, pp. 609-624.

Yule, G.U., (1927), "On a method of investigating periodicities in distributed series with special reference to Wolfer's sunspot numbers", *Transactions of the Royal Society of London Series A, Containing Papers of a Mathematical or Physical Character*, Vol. 226, pp. 267-298.

Zhang, W., Zhao, S., (2013), "Forecasting Research on The Total Volume of Import and Export Trade of Ningbo Port by Gray Forecasting Model, *Journal of Software*, Vol. 8, Issue 2, pp. 466-471.



BIOGRAFI PENULIS



Penulis dilahirkan di Kediri, tepatnya di desa Sitimerto, Kecamatan Pagu, Kabupaten Kediri, Jawa Timur pada tanggal 9 Juli 1982, putri kedua dari tiga bersaudara buah cinta dari pasangan Bapak Tjipto Rahardjo dan Ibu Elizabeth Setyo Rahayu. Riwayat pendidikan penulis adalah SD Negeri Sudimara VII Ciledug – Tangerang (1988-1994), SMP Negeri 3 Tangerang (1994-1997), SMU Negeri 1 Tangerang (1997-2000), Sekolah Tinggi Ilmu Statistik (STIS) Jakarta peminatan Sosial Kependudukan (2000-2004). Setelah menamatkan pendidikan D IV di STIS, penulis ditugaskan bekerja di BPS Kabupaten Belu, Provinsi Nusa Tenggara Timur sebagai staf seksi Neraca Wilayah dan Analisis Statistik. Pada tahun 2009, penulis dipercaya menjabat sebagai Kepala Seksi Neraca Wilayah dan Analisis Statistik. Kemudian pada tahun 2013 penulis dimutasi ke BPS Kota Kupang, Provinsi Nusa Tenggara Timur sebagai Kepala Seksi Statistik Produksi. Pada tahun 2014 penulis memperoleh kesempatan beasiswa dari BPS untuk melanjutkan studi S2 di Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Institut Teknologi Sepuluh Nopember (ITS) Surabaya.

Alamat e-mail: eunike_wp@yahoo.com; eunike_wp@hotmail.com