



TUGAS AKHIR - KS 141501

PERAMALAN DATA INTERMITEN MENGGUNAKAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE DAN NEURAL NETWORK (ARIMA-NN)

***FORECASTING INTERMITTENT DATA USING
AUTOREGRESSIVE INTEGRATED MOVING
AVERAGE AND NEURAL NETWORK (ARIMA-NN)
METHOD***

RIMA IKA AGUSTIN
NRP 5214 100 011

Dosen Pembimbing
Wiwik Anggraeni, S.Si., M.Kom

DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember
Surabaya 2018



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS 141501

PERAMALAN DATA INTERMITEN MENGGUNAKAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE DAN NEURAL NETWORK (ARIMA-NN)

RIMA IKA AGUSTIN
NRP 5214 100 011

Dosen Pembimbing
Wiwik Anggraeni, S.Si., M.Kom.

DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember
Surabaya 2018



ITS
Institut
Teknologi
Sepuluh Nopember

FINAL PROJECT - KS 141501

FORECASTING INTERMITTENT DATA USING AUTOREGRESSIVE INTEGRATED MOVING AVERAGE AND NEURAL NETWORK (ARIMA- NN) METHOD

RIMA IKA AGUSTIN
NRP 5214 100 011

Supervisors
Wiwik Anggraeni, S.Si., M.Kom.

INFORMATION SYSTEMS DEPARTMENT
Faculty of Information Technology and Communication
Institut Teknologi Sepuluh Nopember
Surabaya 2018

LEMBAR PENGESAHAN

PERAMALAN DATA INTERMITEN MENGGUNAKAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE DAN NEURAL NETWORK (ARIMA-NN)

Disusun untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada

Departemen Sistem Informasi
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember

Oleh:

Rima Ika Agustin
5214 100 011

Surabaya, 16 Januari 2018

**Plh Kepala
Departemen Sistem Informasi**

Edwin Riksakomara, S.Kom, MT.
NIP 19690725 200312 1 001



LEMBAR PERSETUJUAN

PERAMALAN DATA INTERMITEN MENGGUNAKAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE DAN NEURAL NETWORK (ARIMA-NN)

TUGAS AKHIR

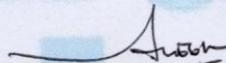
Disusun untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada

Departemen Sistem Informasi
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember

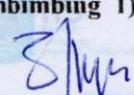
Oleh
Rima Ika Agustin
5214 100 011

Disetujui Tim Penguji Tanggal Ujian : 15 Januari 2018
Periode Wisuda: Maret 2018

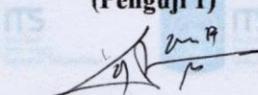
Wiwik Anggraeni, S.Si., M.Kom.


(Pembimbing 1)

Edwin Riksakomara, S.Kom., M.T.


(Penguji 1)

Faizal Mahananto, S.Kom., M.Eng., Ph.D.


(Penguji 2)

PERAMALAN DATA INTERMITEN MENGGUNAKAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE DAN NEURAL NETWORK (ARIMA-NN)

Nama Mahasiswa

: Rima Ika Agustin

NRP

: 5214100011

Departemen

: SISTEM INFORMASI FTIK-ITS

Dosen Pembimbing

: Wiwik Anggraeni, S.Si., M.Kom

ABSTRAK

Pola data intermiten merupakan pola permintaan yang terjadi secara terputus-putus dimana tidak dapat diselesaikan dengan metode deret waktu konvensional. Ketidakakuratan pola data yang terjadi menimbulkan suatu pengembangan metode tertentu untuk menangani data tersebut, sehingga pada tugas akhir ini akan menyelesaikan permasalahan data intermiten dengan menerapkan metode ARIMA-NN. Hal ini dilakukan karena pada studi literatur telah ditemukan banyak penelitian data intermiten yang menggunakan metode hybrid ARIMA-NN yang dinilai cukup baik dalam menyelesaikan permasalahan tersebut. Alasan penggabungan kedua metode ini adalah karena adanya asumsi bahwa metode tunggal tidak dapat secara total mengidentifikasi semua karakteristik time series. Oleh karena itu peramalan metode ARIMA-NN dilakukan untuk mengetahui prediksi pada data intermiten beberapa tahun kedepan yang berguna untuk membantu instansi dalam pengambilan keputusan. Hasil dari penelitian tugas akhir ini difokuskan pada penemuan model terbaik dan keakuratan hasil peramalan dengan mengetahui nilai error yang kecil yang kemudian dapat memberikan keputusan dalam peramalannya. Pada tugas akhir ini dilakukan peramalan terhadap data intermiten untuk menyelesaikan ketidakakuratan pola yang terjadi dalam permintaan tertentu guna membantu instansi dalam pengambilan keputusan. Model

ARIMA-ANN dapat digunakan untuk meramalkan jumlah impor beras. Model ARIMA terbaik yang digunakan adalah (1,0,0). Model ARIMA ini dilanjutkan dengan menggunakan metode ANN dengan input layer sebanyak 12 neuron, hidden layer sebanyak 7 neuron, dan output layer sebanyak 1 neuron. Sehingga model ARIMA-ANN dapat meramalkan jumlah impor beras pada periode selanjutnya. *Hasil peramalan jumlah impor beras menggunakan metode ARIMA-ANN memiliki nilai MDA 67.1% pada data training lalu MDA 70.3% pada data testing yang menunjukkan bahwa model memiliki tingkat keakuratan yang cukup baik.*

Kata kunci : intermiten, hybrid, Autoregressive, Moving Average, Neural Network

FORECASTING INTERMITTENT DATA USING AUTOREGRESSIVE INTEGRATED MOVING AVERAGE AND NEURAL NETWORK (ARIMA- NN) METHOD

Name	: Rima Ika Agustin
NRP	: 5214100011
Departement	: SISTEM INFORMASI FTIK-ITS
Supervisor	: Wiwik Anggraeni, S.Si., M.Kom

ABSTRACT

Intermittent data patterns are dashed patterns of demand that can not be solved by conventional time series methods. The irregularity of data patterns that occur lead to a development of certain methods to handle the data, so that in this final project will solve the problem of intermittent data by applying ARIMA-NN method. This is done because in the literature study has found a lot of intermittent data research using hybrid ARIMA-NN method is considered good enough in solving the problem. The reason for merging these two methods is because of the assumption that a single method can not totally identify all time series characteristics. Therefore, ARIMA-NN forecasting method is done to know the prediction on intermittent data several years ahead which is useful to assist the agency in decision making. The results of this final project research focused on finding the best model and accuracy of forecasting results by knowing the small error value which then can give a decision in forecasting. In this final project is done forecasting of intermittent data to solve pattern irregularity that occur in certain request to assist agency in decision making. The ARIMA-ANN model can be used to predict the amount of rice imports. The best ARIMA model used is (1,0,0). ARIMA model is continued by using ANN method with 12 layer input of neuron, hidden layer as much as 7 neurons, and output layer as

much as 1 neuron. So the ARIMA-ANN model can predict the amount of rice import in the next period. The result of forecasting the amount of rice import using ARIMA-ANN method has MDA value of 67,1% in training data then MDA 70,3% in data testing showing that the model has a middle level of accuracy.

Keywords: *intermittent, hybrid, Autoregressive, Moving Average, Neural Network.*

KATA PENGANTAR

Puji syukur kepada Allah SWT atas segala rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan Tugas Akhir dengan judul **“PERAMALAN DATA INTERMITEN MENGGUNAKAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE AND NEURAL NETWORK (ARIMA-NN)”** yang merupakan salah satu syarat untuk kelulusan pada Departemen Sistem Informasi Fakultas Teknologi Informasi dan Komunikasi Institut Teknologi Sepuluh Nopember Surabaya. Selama melaksanakan Tugas Akhir ini, penulis menemukan banyak pihak yang telah membantu dan memberikan saran. Atas bantuan yang telah diberikan, penulis mengucapkan terimakasih kepada:

1. Allah SWT yang telah memberikan segala rahmat dan karunia yang telah memberikan kemudahan, kelancaran serta kesehatan selama penggerjaan Tuhas Akhir di Departemen Sistem Informasi ITS.
2. Kedua orang tua dan Adek Akbar yang senantiasa mendoakan kelancaran dan kesuksesan serta mendukung dalam penggerjaan Tugas Akhir ini.
3. Ibu Wiwik Anggraeni, S.Si, M.Kom selaku dosen pembimbing yang memberikan arahan dan bimbingan selama penggerjaan Tugas Akhir hingga penyusunan laporan.
4. Bapak Edwin Riksakomara, S.Kom, M.T dan Bapak Faisal Mahananto, S.Kom, M.Eng, Ph.D selaku dosen penguji yang selalu memberikan saran dan masukan selama Tugas Akhir ini.
5. Bapak Achmad Holil Noor Ali selaku dosen wali penulis yang selalu memberikan motivasi, wejangan, dukungan dan saran selama penulis menempuh pendidikan S1.

6. Untuk sahabat-sahabatku Squad Teman Masa Gitu yang selalu memberikan motivasi dan semangat dalam kuliah dan penggerjaan Tugas Akhir.
7. Sahabat-sahabatku di Beastudi Etos Surabaya terkhusus untuk ACTION'14 dan di JMMI terkhusus kabinet INSPIRASI 1718 yang selalu setia menemani perjuangan dan memotivasi untuk menyelesaikan Tugas Akhir.
8. Teman-teman OSIRIS dan semua pihak yang selalu mendukung dan memberi semangat dalam penggerjaan Tugas Akhir.
9. Seluruh dosen pengajar, staff dan karyawan di Departemen Sistem Informasi FTIK ITS Surabaya yang telah memberikan ilmu dan bantuan kepada penulis selama ini.
10. Serta semua pihak yang telah membantu dalam penggerjaan Tugas Akhir ini yang belum mampu penulis sebutkan diatas.

Terima kasih atas segala bantuan, dukungan, serta doa yang diberikan. Semoga Allah SWT senantiasa memberikan kesehatan, keselamatan, karunia dan nikmat-Nya.

Penulis pun ingin memohon maaf karena penulis menyadari bahwa Tugas Akhir ini masih belum sempurna. Selain itu penulis bersedia untuk menerima kritik dan saran terkait dengan Tugas Akhir ini. Semoga Tugas Akhir ini dapat bermanfaat bagi seluruh pembaca.

Surabaya, Januari 2018

Penulis

DAFTAR ISI

ABSTRAK	ii
ABSTRACT	iv
KATA PENGANTAR.....	vi
DAFTAR ISI	viii
DAFTAR GAMBAR.....	xii
DAFTAR TABEL	xiv
BAB I PENDAHULUAN	1
1.1. Latar belakang	1
1.2 Rumusan permasalahan	4
1.3 Batasan permasalahan.....	4
1.4 Tujuan.....	4
1.5 Manfaat.....	4
1.6 Relevansi	5
1.7 Sistematika penulisan	6
BAB II TINJAUAN PUSTAKA	7
2.1 Studi sebelumnya.....	7
2.2 Dasar teori.....	8
2.2.1. Konsep Umum Peramalan	8
2.2.2. Data Intermitten	10
2.2.3. Neural Network.....	10
2.2.4. Metode ARIMA (<i>Autoregressive Integgrated Moving Average</i>).....	17
2.2.5. Uji Akurasi atau Performa Model Peramalan	
21	
2.2.6. ARIMA-NN	22
BAB III METODE PENGERJAAN TUGAS AKHIR....	26
3.1. Tahapan pelaksanaan tugas akhir	26
3.2. Uraian metodologi	26
3.2.1. Studi literatur	26
3.2.2. Persiapan Data	27
3.2.3. Proses Analisis Model ARIMA	27
3.2.3.1. Analisa Data.....	27

3.2.3.2. Uji Stasioner Data.....	27
3.2.3.3. Pemodelan ARIMA	28
3.2.3.4. Peramalan ARIMA	29
3.2.4. Model NN	29
3.2.4.1. Pelatihan	29
3.2.4.2. Pengujian	29
3.2.4.3. Peramalan dengan ANN	30
3.2.5. Dokumentasi Tugas Akhir.....	30
BAB	IV
PERANCANGAN.....	32
4.1 Persiapan Data.....	32
4.1.1 Pengumpulan Data.....	32
4.1.2 Pra-proses Data.....	32
4.2 Model Penelitian Menggunakan ARIMA	32
4.2.1 Gambaran Data Masukan	33
4.2.2 Uji Stasioner Ragam.....	33
4.2.3 Transformasi Data	33
4.2.4 Uji Stasioner Rataan	34
4.2.5 Differencing Data	34
4.2.6 Pemodelan dan Estimasi Parameter ARIMA	
34	
4.2.7 Uji Signifikansi ARIMA.....	34
4.2.8 Uji Diagnostik Parameter ARIMA	35
4.2.9 Penentuan Model Terbaik ARIMA	35
4.2.10 Uji Akurasi Model Peramalan	35
4.3 Metode ARIMA-NN	36
4.3.1 Pra-proses Data.....	36
4.3.2 Perancangan Model ANN.....	36
4.3.3 Peramalan Data.....	37
4.3.4 Ketepatan Model Peramalan.....	37
4.3.5 Peramalan Periode Mendatang	38
BAB V IMPLEMENTASI.....	40
5.1 Implementasi Model ARIMA	40
5.1.1 Menentukan Training Set dan Testing Set... 40	
5.1.2 Uji Stasioner Ragam.....	41
5.1.3 Tranformasi Data	42

5.1.4	Uji Stasioner Rataan	44
5.1.5	Estimasi Parameter.....	45
5.1.6	Uji Signifikansi Model.....	46
5.1.7	Uji Diagnostik Parameter.....	48
5.1.8	Pemilihan Model Terbaik ARIMA Sementara 50	
5.1.9	Peramalan Model Terbaik.....	50
5.2	Implementasi Model ARIMA-NN.....	51
5.2.1	Pemrosesan Data.....	51
5.2.2	Uji Validasi Data.....	54
5.2.3	Perancangan <i>Artificial Neural Network</i>	54
5.2.4	Menentukan Parameter <i>Artificial Neural Network</i>	55
5.2.5	Penerapan Model <i>Artificial Neural Network</i>	56
5.2.6	Pengujian.....	57
5.2.7	Peramalan Periode Kedepan	57
BAB VI HASIL DAN PEMBAHASAN	60	
6.1	Hasil Uji Coba Model ARIMA.....	60
6.2	Hasil Uji Coba Parameter Model ANN	62
6.3	Analisis Hasil Peramalan ARIMA-NN.....	64
6.4	Analisis Perbandingan Hasil Peramalan Data Transformasi dan Dtransformasi	65
BAB VII KESIMPULAN DAN SARAN	68	
7.1	Kesimpulan	68
7.2	Saran	68
DAFTAR PUSTAKA	70	
BIODATA PENULIS	74	
LAMPIRAN A	76	
LAMPIRAN B	82	
LAMPIRAN C	94	
LAMPIRAN D	106	
LAMPIRAN E	112	

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 2.1 Proses Komunikasi Antara Neuron.....	11
Gambar 2.2 Arsitektur Multilayer Neural Network	14
Gambar 3.1 Metodologi Penelitian Tugas Akhir.....	26
Gambar 4.1 Grafik Data Training Jumlah Impor Beras	33
Gambar 5.1 Grafik Data Training.....	40
Gambar 5.2 Grafik Data Testing	41
Gambar 5.3 Grafik Data Transformasi Awal Jumlah Impor Beras.....	41
Gambar 5.4 Hasil Uji Stasioner Ragam.....	42
Gambar 5.5 Grafik Perbandingan Transformasi.....	43
Gambar 5.6 Hasil Uji Stasioner Ragam Kedua	43
Gambar 5.7 Hasil Uji Stasioner Rataan.....	44
Gambar 5.8 Hasil Correlogram untuk Transformasi Data....	45
Gambar 5.9 Hasil Uji Signifikansi Model ARIMA (1,0,0) ...	46
Gambar 5.10 Uji Keacakan Sisaan Model ARIMA (1,0,0)....	48
Gambar 5.11 Uji Homogenitas Model ARIMA (1,0,0).....	49
Gambar 5.12 Hasil Peramalan Model Terbaik pada Data Transformasi Kedua	51
Gambar 5.13 Tab Preprocess pada Weka	53
Gambar 5.14 Fungsi Multilayer Perceptron	53
Gambar 5.15 Menu Test Options	54
Gambar 5.16 Weka GUI Generate Editor	55
Gambar 5.17 Arsitektur ANN	56
Gambar 5.18 Summary Apply Model	57
Gambar 5.19 Classifier evaluation options.....	58
Gambar 5.20 Hasil Peramalan Model ANN	58
Gambar 6.1 Hasil Peramalan Uji Coba Model ARIMA pada Testing Set (Data Transformasi).....	60
Gambar 6.2 Perbandingan Data Aktual dan Peramalan	61
Gambar 6.3 Summary ANN pada Data Training	62
Gambar 6.4 Summary ANN pada Data Testing	63
Gambar 6.5 Perbandingan Data Aktual (Training) dan Peramalan dengan Model ANN.....	64

Gambar 6.6 Perbandingan Data Aktual (Testing) dan Peramalan dengan Model ANN	64
Gambar 6.7 Hasil Peramalan Periode Mendatang (Data Transformasi)	65
Gambar 6.8 Perbandingan Data Aktual dan Prediksi pada Data Training	66
Gambar 6.9 Perbandingan Data Aktual dan Prediksi pada Data Testing.....	66
Gambar 6.10 Grafik Hasil Peramalan	67

DAFTAR TABEL

Tabel 2.1 Penelitian Sebelumnya 1	7
Tabel 2.2 Penelitian Sebelumnya 2	7
Tabel 2.3 Penelitian Sebelumnya 3	8
Tabel 4.1 Rancangan Model ANN	37
Tabel 5.1 Daftar Estimasi Parameter.....	45
Tabel 5.2 Hasil Uji Signifikansi Model ARIMA	47
Tabel 5.3 Uji Diagnostik ARIMA pada Jumlah Impor Beras	49
Tabel 5.4 Daftar Nilai AIC dan SIC pada Model ARIMA Sementara	50
Tabel 5.5 Data Training Jumlah Impor Beras	52
Tabel 5.6 Data Testing Jumlah Impor Beras	52
Tabel 5.7 Hasil <i>Trial and Error</i> pada <i>Epoch, Momentum</i> dan <i>Learning Rate</i>	55
Tabel 6.1 Perbandingan Hasil Uji Coba Model ARIMA	61
Tabel 6.2 Daftar Parameter Model ANN	62
Tabel 6.3 Perbandingan Hasil Uji Coba Model ANN	63
Tabel 6.4 Perbandingan Hasil Peramalan.....	67

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

Bab ini menjelaskan tentang Gambaran secara umum tugas akhir yang disusun. Gambaran tersebut meliputi latar belakang masalah mengapa tugas akhir ini disusun, perumusan masalah yang akan diselesaikan, batasan tugas akhir, tujuan tugas akhir, serta manfaat yang ditimbulkan oleh tugas akhir yang disusun. Selain itu akan dijelaskan relevansi tugas akhir dengan bidang keilmuan serta pengaplikasiannya dalam kehidupan sehari-hari.

1.1. Latar belakang

Indonesia adalah salah satu yang dianggap sebagai negara ekonomi awal dan berkembang menurut Laporan Ekonomi Dunia Dana Moneter Internasional pada April 2010 [1]. Seiring dengan berkembangnya pertumbuhan ekonomi di Indonesia, pemerintah memerlukan data permintaan terkini yang digunakan sebagai landasan dalam perumusan kebijakan perdagangan internasional untuk meningkatkan perekonomian Indonesia. Data permintaan internasional terkini yang tersedia adalah data kegiatan ekspor dan impor pada rentang waktu tertentu. Dimana data ekspor atau impor yang terjadi di Indonesia ini memiliki sifat yang intermiten, yaitu data bersela yang berhenti untuk sementara waktu lalu menyambung kembali [2]. Seperti halnya kegiatan ekspor dan impor ini memiliki pola data yang tidak beraturan setiap bulannya.

Dari uraian diatas maka perlu adanya peramalan untuk data yang bersifat intermiten tersebut agar dapat membantu proses pengambilan keputusan dalam memberikan kebijakan dalam permintaan di Indonesia.

Metode time series konvensional tidak dapat mengatasi permasalahan tersebut. Maka dari itu pada data intermiten tersebut, dapat dilakukan dengan menggunakan model *hybrid Autoregressive Integrated Moving Average – Neural Network*

(ARIMA-NN). Model ARIMA digunakan untuk menyelesaikan deret berkala pada data time series. Model ini baik digunakan untuk meramalkan data jangka pendek, sedangkan untuk meramalkan data jangka panjang kurang baik. Model ARIMA ini adalah model yang tepat apabila hasil pengamatan dari time seriesnya tidak berhubungan antara satu dengan yang lain (univariate). Model ARIMA ini sangat fleksibel memiliki beberapa jenis runtun waktu yang berbeda yaitu moodel *Autoregressive* (AR) dan *Moving Average* (MA) serta kombinasi keduanya yaitu ARMA yang dapat diasumsikan sebagai model linier [3]. Kekurangan dari model ARIMA adalah bersifat linear sehingga tidak dapat menangkap pola-pola non-linear yang terdapat pada *time series*. Maka dari itu, model ARIMA perlu model yang dapat menangkap pola-pola non-linear, dan model tersebut adalah NN[4].

Kelebihan dari NN ini adalah memiliki sifat yang fleksibel dalam memodelkan non-linear karena dengan menggunakan NN maka dalam memodelkan nonlinier tidak membutuhkan bentuk model yg tetap melainkan model akan dengan adaptif dibentuk berdasarkan model yang ditampilkan dari data[5].

Sehingga kombinasi antara ARIMA dan NN ini akan menghasilkan peramalan yang linier dan nonlinier. Perlu diketahui, bahwa dalam peramalan tidak ada metode yang sangat tepat untuk digunakan dalam meramalkan suatu keadaan atau kegiatan tertentu di masa yang akan datang, karena setiap metode peramalan pasti memiliki kesalahan atau error., sehingga dalam penelitian ini juga akan menghitung kesalahan pada sebuah peramalan tersebut menggunakan *Mean Absolute Percentage Error* (MAPE).

Penelitian sebelumnya dengan membandingkan metode RNN (*Recurrent Neural Network*) dan ARIMA tentang peramalan inflasi di Ghana yang dilakukan oleh Econ, Manag Hadrat dkk dengan judul *Inflation Forecasting in Ghana-Artificial Neural Network*, dimana hasil penelitian tersebut menyatakan bahwa

peramalan menggunakan RNN menunjukkan hasil yang lebih baik dari ARIMA. Penelitian selanjutnya oleh Ananda Citra Islami dengan judul “Peramalan Harga Beli Beras Riil dan Produk di Beras di Provinsi Jawa Timur”, penelitian ini meramalkan dan memodelkan harga beras riil serta produksi beras yang ada di Provinsi Jawa Timur menggunakan metode ARIMA Box-Jenkins, dimana hasil dari penelitian tersebut adalah untuk menganalisis data harga beras menggunakan metode *regresi time series* dan untuk produksi berasnya menggunakan metode *regresi time series dummy* 12 bulan. Kemudian penelitian tentang “Pemodelan Curah Hujan dengan Pendekatan ARIMA, Feedforward Neural Network dan ARIMA-NN di Banyuwangi” oleh Yudi Santoso dkk menjelaskan bahwa tujuan dari penelitian ini adalah untuk membantu petani dalam produksi padi di Banyuwangi karena faktor alam berpengaruh dalam produksi padi terutama curah hujan. Dari hasil penelitian tersebut menunjukkan bahwa didapatkan pemodelan ARIMA $([1,13,17],0,0)(1,0,0)12$, FFNN $(3,3,1)$ dengan input $Zt-1, Zt-12$, dan $Zt-13$, dan hybrid (ARIMA-NN) gabungan model ARIMA $([1,13,17],0,0)(1,0,0)12$ dan residualnya dimodelkan kembali dengan model FFNN $(4,5,1)$ dimana variable inputnya adalah at-1 hingga at-4.

Sehingga tujuan penelitian tugas akhir ini yaitu membuat model peramalan dengan mengkombinasikan metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Neural Network* (NN) yang dapat meramalkan jumlah penerimaan impor beras di Provinsi Jawa Timur. Dengan menggunakan metode ARIMA dapat menemukan hasil peramalan linier dan dengan mengkombinasikan dengan NN dapat menemukan hubungan linier dan nonlinier. Peramalan dengan menggunakan ARIMA ataupun NN belum bisa dipastikan model mana yang benar-benar mempunyai keakuratan yang lebih tinggi, sehingga pada penggeraan tugas akhir ini akan dilakukan pengujian kombinasi ARIMA dan NN. Harapannya dalam penelitian ini dapat membantu instansi dalam membuat kebijakan keputusan

1.2 Rumusan permasalahan

Rumusan masalah dari tugas akhir ini adalah sebagai berikut:

1. Bagaimana model ARIMA-NN terbaik yang dapat digunakan untuk meramalkan data intermiten ?
2. Bagaimana hasil dan tingkat akurasi peramalan data intermiten dengan menggunakan metode ARIMA-NN?

1.3 Batasan permasalahan

Batasan dalam pengerjaan tugas akhir ini adalah:

1. Data yang digunakan dalam tugas akhir ini yaitu data Realisasi Penerimaan Beras Luar Negeri.
2. Data yang digunakan adalah data bulanan pada periode Januari 2002 hingga Desember 2016.

1.4 Tujuan

Tujuan yang hendak dicapai dalam pengerjaan tugas akhir ini adalah :

1. Menemukan model terbaik untuk peramalan data intermiten dengan menggunakan metode ARIMA-NN.
2. Mengetahui hasil dan tingkat akurasi dalam peramalan data intermiten menggunakan metode ARIMA-NN.

1.5 Manfaat

Manfaat yang diberikan dengan adanya tugas akhir ini adalah sebagai berikut:

1. Bagi Penulis
Dapat mempraktikkan atau mengimplementasikan dan mengembangkan ilmu pengetahuan serta metode yang diperoleh selama perkuliahan pada studi kasus yang nyata.
2. Bagi Instansi
Memudahkan instansi atau organisasi dalam melakukan pengambilan keputusan terkait peramalan data intermiten. Dengan demikian dapat

mendukung proses perencanaan dan pengelolahan produk atau rantai pasok yang ada pada instansi atau organisasi.

3. Bagi Masyarakat

Menambah sumber pengetahuan dan pembelajaran bagi masyarakat mengenai data intermiten yang dapat mendukung keputusan. Pembelajaran tersebut dapat diterapkan dalam penyelesaian suatu permasalahan yang serupa dan dapat dijadikan acuan untuk mengembangkan penelitian selanjutnya.

1.6 Relevansi

Topik tugas akhir ini yaitu mengenai peramalan pada pola data intermiten, data tersebut sering terjadi pada kondisi-kondisi tertentu seperti pada data demand, ekpor, impor dan lainnya. Pola data intermiten terjadi secara terputus-putus yang tidak dapat diselesaikan dengan metode deret waktu konvensional. Ketidakakuratan pola data menimbulkan suatu pengembangan metode tertentu, sehingga pada tugas akhir ini akan menyelesaikan permasalahan data intermiten dengan menerapkan metode ARIMA-NN. Hal ini dilakukan karena telah pada studi literatur ditemukan banyak penelitian data intermiten yang menggunakan metode *hybrid* ARIMA-NN yang dinilai cukup baik dalam menyelesaikan permasalahan tersebut. Maka dari itu peramalan metode ARIMA-NN dilakukan untuk mengetahui prediksi pada data intermiten beberapa tahun kedepan yang berguna untuk membantu instansi dalam pengambilan keputusan. Hasil dari penelitian tugas akhir ini difokuskan pada penemuan model terbaik dan keakuratan hasil peramalan dengan mengetahui nilai error yang kecil yang kemudian dapat memberikan keputusan dalam peramalannya.

Penelitian tugas akhir ini termasuk dalam mata kuliah Statistik, Sistem Pendukung Keputusan, Teknik Peramalan, Penggalian Data dan Analitika Bisnis. Topik ini relevan dengan bidang keilmuan *Computerized Decision Support* pada sub bidang

peramalan, dimana hal tersebut merupakan salah satu roadmap pada Laboratorium Rekayasa Data dan Intelelegensi Bisnis (RDIB) di Departemen Sistem Informasi, Institut Teknologi Sepuluh Nopember.

1.7 Sistematika penulisan

Sistematika Penulisan Laporan Tugas Akhir ini tersebut mencakup:

a. Bab I Pendahuluan

Dalam bab ini dijelaskan mengenai latar belakang, rumusan dan batasan masalah, tujuan dan manfaat pengerjaan tugas akhir.

b. Bab II Tinjauan Pustaka dan Dasar Teori

Dijelaskan mengenai penelitian-penelitian serupa yang telah dilakukan serta teori – teori yang menunjang permasalahan yang dibahas pada tugas akhir ini

c. Bab III Metodologi

Dalam bab ini dijelaskan mengenai tahapan – tahapan apa saja yang harus dilakukan dalam pengerjaan tugas akhir

d. Bab IV Perancangan

Bab ini berisi tentang bagaimana rancangan yang akan digunakan untuk implementasi metode yang digunakan.

e. Bab V Implementasi

Bab yang berisi tentang setiap langkah yang dilakukan dalam implementasi metodologi yang digunakan dalam tugas akhir.

f. Bab VI Analisis Hasil dan Pembahasan

Bab yang berisi tentang analisis dan pembahasan dalam penyelesaian permasalahan yang dibahas pada pengerjaan tugas akhir.

g. Bab VII Kesimpulan dan Saran

Bab yang berisi kesimpulan dan saran yang ditujukan untuk kelengkapan penyempurnaan tugas akhir ini.

BAB II

TINJAUAN PUSTAKA

Bab ini berisi mengenai studi sebelumnya yang berhubungan dengan tugas akhir dan teori - teori yang berkaitan dengan permasalahan tugas akhir.

2.1 Studi sebelumnya

Beberapa penelitian sebelumnya yang dijadikan acuan dalam pengerjaan tugas akhir disajikan dalam tabel 2.1 sampai tabel 2.3.

Tabel 2.1 Penelitian Sebelumnya 1

Nama Peneliti	Econ, Manag Hadrat, Yusif M.K, Eshun Nunoo, Isaac Eric, Effah Sarkodie[6]
Tahun Penelitian	2015
Judul Penelitian	<i>Inflation Forecasting in Ghana-Artificial Neural Network Model Approach</i>
Penjelasan Singkat	Peramalan inflasi di Ghana dengan membandingkan metode RNN dan ARIMA yang melibatkan dua faktor yakni money supply dan kurs.
Hasil Penelitian	Peramalan menggunakan RNN menunjukkan hasil yang lebih baik dari ARIMA.

Tabel 2.2 Penelitian Sebelumnya 2

Nama Peneliti	Ananda Citra Islami[7]
Tahun Penelitian	2014
Judul Penelitian	<i>Peramalan Harga Beli Beras Riil dan Produksi Beras di Provinsi Jawa Timur</i>
Penjelasan Singkat	Meramalkan dan memodelkan harga beras riil serta produksi beras yang ada di Provinsi Jawa Timur menggunakan metode ARIMA Box-Jenkins dan Regresi Time Series.
Hasil Penelitian	Metode regresi time series pada harga beras adalah insample 16963,5 dan outsample 49196,7. Untuk produksi berasa adalah

	insample 53762880128,12 dan outsample 10321766105,11. Sehingga metode yang sesuai untuk menganalisis data harga beras adalah Regresi Time Series dan untuk produksi berasnya menggunakan metode Regresi Time Series Dummy 12 bulan karena menunjukkan nilai MSE pada in dan out yang rendah.
--	--

Tabel 2.3 Penelitian Sebelumnya 3

Nama Peneliti	Yudi Santoso dan Brodjol Sutijo Suprih Ulama[8]
Tahun Penelitian	2016
Judul Penelitian	Pemodelan Curah Hujan dengan Pendekatan Model ARIMA, <i>Feed Forward Neural Network</i> dan <i>Hybrid</i> (ARIMA-NN) di Banyuwangi
Penjelasan Singkat	Penelitian ini memodelkan curah hujan menggunakan pendekatan ARIMA, <i>feed forward neural network</i> , dan <i>hybrid</i> (ARIMA-NN) kegunaannya untuk membantu petani dalam produksi padi di Banyuwangi Karena faktor alam berpengaruh dalam produksi padi terutama curah hujan.
Hasil Penelitian	Kesimpulan dari penelitian ini didapatkan pemodelan ARIMA ([1,13,17],0,0)(1,0,0)12, FFNN (3,3,1) dengan input Zt-1,Zt-12, dan Zt-13, dan <i>hybrid</i> (ARIMA-NN) gabungan model ARIMA ([1,13,17],0,0)(1,0,0)12 dan <i>residualnya</i> dimodelkan kembali dengan model FFNN (4,5,1) dimana variable <i>inputnya</i> adalah at-1 hingga at-4.

2.2 Dasar teori

Sub bab ini berisi teori maupun konsep yang berkaitan dengan tugas akhir yang dikerjakan.

2.2.1. Konsep Umum Peramalan

Peramalan adalah sebuah kegiatan teratur yang memprediksi kejadian di masa depan dengan menggunakan tidak hanya

metode ilmiah, namun juga mempertimbangkan hal-hal yang bersifat kualitatif, seperti perasaan, pengalaman seseorang dan lainnya. Peramalan yang dibuat selalu diupayakan agar dapat meminimumkan pengaruh ketidakpastian. Dengan kata lain peramalan bertujuan mendapatkan peramalan yang bisa meminimumkan kesalahan meramal (*forecast error*) yang bisa diukur dengan *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), dan sebagainya [9].

Metode peramalan dibagi menjadi dua yaitu [10]:

- a. Metode Kualitatif : Peramalan yang didasarkan pada data kualitatif masa lalu yang digabungkan dengan pemikiran dari penyusunnya.
- b. Metode Kuantitatif : Peramalan yang didasarkan pada data kuantitatif dari data sebelumnya dan variabel sebab akibat. Hasil peramalan bergantung pada metode yang akan digunakan, karena setiap metode memiliki hasil peramalan yang berbeda pula. Peramalan secara kuantitatif ini dibagi lagi menjadi dua, yaitu model deret waktu (time series) dan model kasual[11].

Pada materi [12] *forecasting* menjelaskan beberapa teknik peramalan sebagai berikut :

- a. Model deret waktu atau time series : suatu variabel diramalkan berdasarkan nilai variabel itu sendiri pada periode sebelumnya.
- b. Model kasual atau explanatory : suatu variabel diramalkan berdasarkan nilai dari salah satu atau lebih variabel lain yang berepengaruh. Model ini biasanya menggunakan analisis regresi dalam menentukan modelnya karena mencari variabel yang signifikan mempengaruhi variabel dependen. Model kasual juga dapat menggunakan metode ARIMA atau Box-Jenkins dalam menentukan model terbaik yang digunakan dalam peramalan.

Tahapan dalam peramalan adalah sebagai berikut :

- a. Mendefinisikan tujuan
- b. Membuat diagram atau plot data

- c. Memilih model peramalan yang tepat
- d. Melakukan peramalan
- e. Menghitung kesalahan atau error
- f. Memilih metode peramalan dengan kesalahan terendah
- g. Melakukan verifikasi peramalan

2.2.2. Data Intermiten

Data intermiten adalah data yang memiliki sifat berselang [2], artinya adalah data yang fluktuatif pada kondisi-kondisi tertentu dan berjeda di waktu-waktu tertentu. Misalnya pada data permintaan ekspor, impor, da lain-lain yang akan digunakan dalam penelitian ini, data tersebut bersifat intermiten karena pada beberapa waktu tertentu penerimaan impor beras bernilai 0, lalu melonjak menjadi puluhan bahkan ratusan ribu. Data tersebut memiliki pola yang tidak teratur sehingga penyelesaian menggunakan metode deret waktu konvensial.

2.2.3. Neural Network

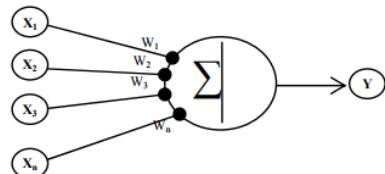
Pada sub bab *Neural Network* ini akan dijelaskan tentang dasar-dasar *Neural Network* yang akan digunakan pada pemodelan peramalan ini. NN adalah prosesor yang terdistribusi paralel, terbuat dari unit-unit yang sederhana, dan memiliki kemampuan untuk menyimpan pengetahuan yang diperoleh secara eksperimental dan siap pakai untuk berbagai tujuan[16].

2.2.3.1. *Artificial Neural Network*

Model multivariate ARIMA cukup fleksibel dalam memodelkan sebagian besar pola time series. Kekurangan dari ARIMA adalah model ARIMA mengasumsikan model yang linier. Hal ini menyebabkan model ARIMA tidak menangkap pola-pola yang non-linear yang umum terdapat pada time series. Oleh karena itu, model tersebut memerlukan model yang dapat menangkap pola-pola yang non-linear. Model tersebut adalah model ANN (*Artificial Neural Network*) [4]. Menurut struktur neuron pada

otak manusia dan proses kerja yang telah dijelaskan sebelumnya, maka konsep dasar pembangunan *Artificial Neural Network* terbentuk. Cara kerja ANN dapat disimpulkan mengadopsi dari cara berpikir sebuah system atau aplikasi yang menyerupai otak manusia, mulai dari menerima input yang diterima, toleransi dari kesalahan atau error, dan juga prosesnya. ANN mempresentasikan buatan dari otak manusia yang selalu melakukan proses pembelajaran pada otak manusia tersebut, di dalam ANN terdapat tiga elemen yang berperan penting sebagai berikut:

- a. Arsitektur jaringan beserta hubungan antar neutron
- b. Algoritma pembelajaran yang berfungsi untuk penggunaan penemuan bobot-bobot jaringan
- c. Fungsi dari aktivasi yang digunakan



Gambar 2.1 Proses Komunikasi Antara Neuron

Pada Gambar 2.1 diperlihatkan bahwa NN terdiri atas satuan-satuan pemroses berupa neuron. Y sebagai *output* menerima *input* dari neuron X₁, X₂, X₃, ..., X_n dengan bobot W₁, W₂, W₃, ..., W_n. Hasil penjumlahan seluruh impuls neuron dibandingkan dengan nilai ambang tertentu melalui fungsi aktivasi setiap neuron. Fungsi aktivasi digunakan sebagai penentu keluaran suatu neuron.

Neural network terdiri dari kumpulan node (neuron) dan relasi. Ada tiga tipe node (neuron) yaitu, *input*, *hidden* dan *output*. Setiap relasi menghubungkan dua

bubah node dengan bobot tertentu dan juga terdapat arah yang menujukkan aliran data dalam proses [17]. Kemampuan otak manusia seperti mengingat, menghitung, mengeneralisasi, adaptasi, diharapkan *neural network* dapat meniru kemampuan otak manusia. *Neural network* berusaha meniru struktur/arsitektur dan cara kerja otak manusia sehingga diharapkan bisa dan mampu menggantikan beberapa pekerjaan manusia. *Neural network* berguna untuk memecahkan persoalan yang berkaitan dengan pengenalan pola, klasifikasi, prediksi dan data mining [18]. *Input node* terdapat pada layer pertama dalam *neural network*. Secara umum setiap *input node* merepresentasikan sebuah input parameter seperti umur, jenis kelamin, atau pendapatan. *Hidden node* merupakan node yang terdapat di bagian tengah. *Hidden node* ini menerima masukan dari *input node* pada layer pertama atau dari *hidden node* dari layer sebelumnya. *Hidden node* mengombinasikan semua masukan berdasarkan bobot dari relasi yang terhubung, mengkalkulasikan, dan memberikan keluaran untuk layer berikutnya. *Output node* mempresentasikan atribut yang diprediksi [17].

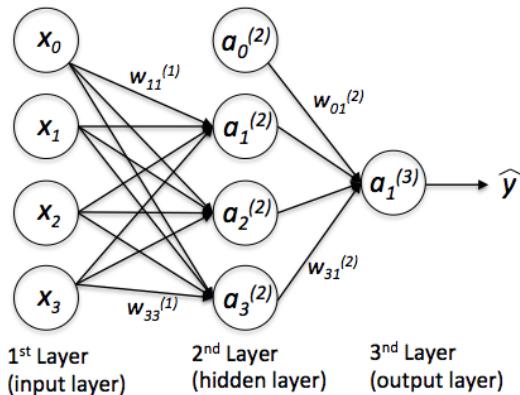
Setiap node (neuron) dalam *neural network* merupakan sebuah unit pemrosesan. Tiap node memiliki beberapa masukan dan sebuah keluaran. Setiap node mengkombinasikan beberapa nilai masukan, melakukan kalkulasi, dan membangkitkan nilai keluaran (aktifasi). Dalam setiap node terdapat dua fungsi, yaitu fungsi untuk mengkombinasikan masukan dan fungsi aktifasi untuk menghitung keluaran. Terdapat beberapa metode untuk mengkombinasikan masukan antara lain *weighted sum*, *mean*, *max*, *logika OR*, atau *logika AND* [17]. Serta beberapa fungsi aktifasi yang dapat digunakan yaitu *heaviside (threshold)*, *step activation*, *piecewise*, *linear*,

gaussian, sigmoid, hyperbolic tangent [19]. Salah satu keuntungan menggunakan neural network adalah bahwa neural network cukup kuat sehubungan dengan data. Karena neural network berisi banyak node (neuron buatan) dengan bobot ditugaskan untuk setiap koneksi [20].

Aplikasi neural network telah banyak dimanfaatkan untuk berbagai kepentingan seperti di bidang Elektronik, Otomotif, Perbankan, Sistem penerbangan udara, Dunia hiburan, transportasi publik, telekomunikasi, bidang Kesehatan, Keamanan, bidang Robotika, Asuransi, Pabrik, Financial, Suara, Pertambangan dan sistem pertahanan [21]. Metode pelatihan terbimbing/terawasi (*supervised learning*) adalah pelatihan yang memasukkan target keluaran dalam data untuk proses pelatihan. Ada beberapa metode pelatihan terbimbing yang telah ditemukan oleh para peneliti, diantaranya adalah yang paling sering diaplikasikan adalah *perseptron* dan *backpropagation (feedforward)*.

2.2.3.2. Metode Backpropagation

Backpropagation merupakan salah satu pengembangan dari arsitektur *Single Layer Neural Network* yang terdiri dari input layer, hidden layer, dan output layer, setiap layer terdiri dari satu atau lebih artificial neuron. Sebutan umum untuk arsitektur ini adalah *multilayer neural network*.



Gambar 2.2 Arsitektur Multilayer Neural Network

Metode ini merupakan metode sistematik dari jaringan saraf tiruan yang menggunakan algoritma *unsupervised learning* dan digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot pada *hidden layer*. Pelatihan yang digunakan pada backpropagation menggunakan pola penyesuaian bobot untuk mencapai nilai kesalahan yang minimum antara keluaran hasil prediksi dengan keluaran yang nyata. Metode ini menggunakan tiga langkah, yaitu:

- Feedforward* dari pola input training
- Backpropagation* dari eror yang terhubung
- Penyesuaian bobot-bobot

2.2.3.3. Pelatihan Standar Backpropagation

Pelatihan backpropagation meliputi tiga fase yang di rangkum sebagai berikut [27]:

- Fase I : Propagasi Maju
Pola inputan dihitung mulai dari layer masukan hingga layer keluaran menggunakan fungsi aktivasi yang ditentukan.
- Fase II : Propagasi Mundur

Selisih antara keluaran jaringan dengan target yang diinginkan merupakan kesalahan yang terjadi. Kesalahan tersebut dipropagasi mundur, dimulai dari garis yang berhubungan langsung dengan unit-unit layer keluaran.

- c. Fase III : Perubahan Bobot
Modifikasi bobot untuk menurunkan kesalahan yang terjadi. Fase ini diiterasi hingga kondisi penghentian terpenuhi.

2.2.3.4. Algoritma Pembelajaran *Backpropagation*

Tahapan dari algoritma pelatihan untuk jaringan dengan satu layer tersembunyi yang memiliki fungsi aktivasi sigmoid biner sebagai berikut[28]:

1. Langkah 0: inisialisasi semua bobot dengan bilangan acak kecil.
2. Langkah 1: jika kondisi penghentian belum terpenuhi, lakukan langkah 2-9.
3. Langkah 2: untuk setiap pasang data pelatihan, lakukan langkah 3-8

Fase I: *Feedforward* (propagasi maju)

4. Langkah 3: tiap unit masukan menerima sinyal dan meneruskannya ke unit tersembunyi diatasnya
5. Langkah 4: Hitung semua keluaran di unit tersembunyi X_j ($j = 1, 2, \dots, p$) dengan persamaan 2.4.

$$z_{netj} = v_{jo} + \sum x_i v_{ini=1} \quad (2.4)$$

Setelah itu menghitung sinyal output dan unit tersembunyi dengan menggunakan fungsi aktivasi pada persamaan 2.5.

$$X_j = f(X_{inj}) \quad (2.5)$$

Sinyal output ini selanjutnya dikirim ke seluruh unit pada unit atas (unit output).

6. Langkah ke 5: Hitung semua keluaran jaringan di unit y_k ($k=1,2,\dots,q$) dengan persamaan 2.6.

$$y_{netk} = w_{ko} + \sum Z_j W_{kj} p_{j=1} \quad (2.6)$$

Selanjutnya menghitung sinyal output dari unit output bersangkutan dengan menggunakan fungsi aktivasi yang telah ditentukan menggunakan rumus pada persamaan 2.7.

$$Y_k = f(Y_ink) \quad (2.7)$$

Fase II: *Backpropagation* (propagasi mundur)

7. Langkah 6: hitung faktor δ unit keluaran berdasarkan kesalahan di setiap unit keluaran y_k ($k=1,2,\dots,q$) menggunakan rumus pada persamaan 2.8.

$$\delta_k = (t_k - y_k) f'(y_{netk}) = (t_k - y_k) y_k (1 - y_k) \quad (2.8)$$

δ_k merupakan unit kesalahan yang akan dipakai dalam perubahan bobot layer dibawahnya (langkah 7). Lalu menghitung suku perubahan bobot w_{kj} (yang akan dipakai untuk merubah bobot w_{kj}) dengan laju percepatan α , yang dirumuskan pada persamaan 2.9.

$$\Delta w_{kj} = \alpha \delta_k z_j \quad (2.9)$$

8. Langkah 7: hitung faktor δ unit tersembunyi berdasarkan kesalahan di setiap unit tersembunyi Z_j ($j=1,2,\dots,p$) menggunakan rumus pada persamaan 2.10.

$$\delta_{netj} = \sum \delta_k w_{kj} m_{k=1} \quad (2.10)$$

Factor δ unit tersembunyi yang dirumuskan pada persamaan 2.11.

$$\delta_j = \delta_{netj} f'(z_{netj}) = \delta_{netj} z_j (1 - z_j) \quad (2.11)$$

Selanjutnya menghitung suku perubahan bobot v_{ji} (yang kan dipakai nanti untuk merubah bobot v_{ji} yang menggunakan rumus pada persamaan 2.12..

$$\Delta v_{ji} = \alpha \delta_j x_i \quad (2.12)$$

Fase III: Perubahan Bobot

9. Langkah 8: Hitung semua perubahan bobot
Perubahan bobot garis yang menuju ke unit keluaran menggunakan persamaan 2.13.

$$w_{kj}(baru) = w_{kj}(lama) + \Delta w_{kj} \quad (2.13)$$

Perubahan bobot garis yang menuju ke unit tersembunyi berdasarkan rumus pada persamaan 2.14.

$$v_{ji}(baru) = v_{ji}(lama) + \Delta v_{ji} \quad (2.14)$$

Setelah pelatihan selesai dilakukan, jaringan dapat dipakai untuk pengenalan pola. Dalam hal ini, hanya *feedforward* (langkah 4 dan 5) saja yang dipakai untuk menentukan keluaran jaringan. Apabila fungsi aktivasi yang dipakai bukan sigmoid biner, maka langkah 4 dan 5 harus disesuaikan. Demikian juga turunannya pada langkah 6 dan 7.

10. Langkah ke-9: tes kondisi berhenti apabila error ditemukan. Jika kondisi STOP telah terpenuhi, maka pelatihan jaringan dapat dihentikan.

2.2.4. Metode ARIMA (*Autoregressive Integrated Moving Average*)

ARIMA disebut dengan metode time series Box-Jenkins. ARIMA atau *Autoregressive Integrated Moving Average* ditemukan oleh George Edward Pelham Box dan Gwilym Meirion Jenkins yaitu metode peramalan untuk menyelesaikan deret berkala untuk menganalisis *time series*. Metode ARIMA sangat baik digunakan untuk meramalkan data untuk jangka pendek sedangkan untuk peramalan jangka panjang ketepatan terhadap peramalannya kurang baik. Model ARIMA adalah model *univariate*, sehingga model ini cocok jika observasi dari time series secara statistik tidak berhubungan satu sama lain.

ARIMA memiliki sifat yang fleksibel (mengikuti pola data), memiliki tingkat akurasi peramalan yang cukup tinggi. Mengikuti pola data disini maksudnya adalah jika data tidak stasioner, data tersebut dapat disesuaikan menjadi data stasioner dengan melakukan *differencing*.

Kelebihan dari ARIMA dapat dijabarkan sebagai berikut[13]:

- a. Mudah dalam pembentukan modelnya.
- b. Lebih cepat dalam pembentukan model, tidak perlu melakukan uji pelatihan seperti ANN.
- c. Hasilnya mudah diinterpretasikan, karena koefisien-koefisien model diketahui.

Kekurangan dari ARIMA adalah[14]:

- a. Secara umum lebih tidak akurat dibandingkan model ANN.
- b. Tidak menangkap hubungan fungsional yang belum diketahui antara variable independen dengan variable dependen / tidak dapat menangkap hubungan antar variable yang belum memiliki teori yang melandasinya.

Klasifikasi model ARIMA telah dibagi menjadi tiga kelompok diantaranya yaitu, model *Autoregressive* (AR), model *Moving Average* (MA), dan model campuran yang memiliki karakteristik dari dua model pertama (ARMA). Model ARIMA merupakan gabungan antara model *Autoregressive* (AR) dan model *Moving Average* (MA) dengan data yang telah mengalami *differencing* atau pembedaan sebanyak *d* kali.

2.2.4.1. Model *Autoregressive* (AR)

Model *Autoregressive* (AR) memiliki nilai data sekarang tergantung dengan nilai data masa lalu, dengan bentuk umum dengan ordo *p* (AR(*p*)) atau

model ARIMA ($p, 0, 0$) dinyatakan pada persamaan 2.15.

$$X_t = \mu' + \theta_1 X_{t-1} + \theta_2 X_{t-2} + \dots + \theta_p X_{t-p} + e_t \quad (2.15)$$

Dimana:

- X_t : Variabel yang diramalkan atau variable tidak bebas
- $X_{t-1}, X_{t-2}, X_{t-3}, \dots, X_{t-p}$: Variabel bebas yang merupakan lag dari variable tidak bebas.
- μ' : suatu konstanta
- θ_p : Parameter Autoregressive ke- p
- e_t : nilai kesalahan pada saat t

Pada persamaan ordo p atau AR(p) adalah jumlah observasi masa lampau yang akan dimasukkan dalam meramalkan periode yang akan datang. Dalam hal ini pula yang menjadi variable bebas adalah dengan variable yang sama (auto variable) tetapi pada periode sebelumnya ($t-1, t-2, t-3, \dots, t-p$).

2.2.4.2. Model Moving Average (MA)

Model Moving Average (MA) memiliki nilai data sekarang tergantung dari peramalan *error* pada periode sebelumnya, dengan bentuk umum dengan ordo q (AR(q)) atau model ARIMA ($0, 0, q$) dinyatakan persamaan 2.16.

$$X_t = \mu' + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.16)$$

Dimana:

- X_t : Variabel yang diramalkan atau variable tidak bebas
- μ' : Suatu konstanta

- $\theta_1, \theta_2, \dots, \theta_q$: Parameter *Moving Average* ke- q
- e_{t-k} : Nilai kesalahan pada saat $t - k$

2.2.4.3. Model Autoregressive Moving Average (ARMA)

Model umum untuk campuran AR (p) dan MA (q) atau sering kali disebut dengan model ARMA (p, q) atau ARIMA (p, d, q) dinyatakan dalam persamaan 2.17.

$$X_t = \mu + \phi_1 X_{t-1} + \cdots + \phi_p X_{t-p} - e_t - \phi_1 e_{t-1} - \cdots - \phi_q e_{t-p} \quad (2.17)$$

2.2.4.4. Integrated (I)

Bentuk umum model *integreted* dengan ordo d ($I(d)$) atau model ARIMA ($0, d, 0$), model *integrated* menyatakan *difference* dari data. Model ini mengartikan bahwa dalam membuat model ARIMA memiliki syarat stasioner data, apabila data telah stasioner pada level maka ordo memiliki nilai 0. Namun jika data telah stasioner pada *different* pertama maka memiliki ordo 1 atau ARIMA ($p, 1, q$).

2.2.4.5. Model Autoregressive Integrated Moving Average (ARIMA)

Adapun langkah-langkah yang harus diambil dalam menganalisis data dengan teknik Box-Jenkins atau ARIMA adalah sebagai berikut [15]:

- a. Identifikasi Model : Memilih model yang tepat dengan membuat plot data agar dapat diketahui pola data yang ada, jika data tidak stasioner maka data di stasionerkan terlebih dahulu, lalu menghitung dan mencocokkan ACF dan PACF

dan yang terakhir adalah menghitung dan mencocokkan sampel ACF dan PACF.

- b. Estimasi Parameter : Memilih taksiran model yang baik dengan cara melakukan uji hipotesis pada parameter.
- c. Uji Diagnostik : Memilih model yang terbaik dan sesuai lalu menggunakan model tersebut untuk peramalan.
- d. Peramalan : Melakukan peramalan sesuai dengan model yang di dapat pada uji diagnostik.

2.2.5. Uji Akurasi atau Performa Model Peramalan

Evaluasi model diperlukan untuk mengukur keampuhan model yang ditemukan, pengukuran akurasi dapat menggunakan beberapa metode [25]. Ada tiga cara yang digunakan dalam penelitian ini untuk mengukur keakurasaian model yaitu MAD, RMSE dan MDA.

a. MAD (*Mean Absolute Deviation*)

Mean Absolute Deviation (MAD) mengukur ketepatan ramalan dengan merata-rata kesalahan dugaan (nilai absolut masing-masing kesalahan). MAD berguna ketika mengukur kesalahan ramalan dalam unit yang sama sebagai deret asli. Nilai MAD dapat dihitung dengan sesuai dengan persamaan 2.18.

$$MAD = \sum \left(\frac{\text{Absolut dari forecast error}}{n} \right) \quad (2.18)$$

b. RMSE (*Root Mean Squared Error*)

RMSE biasanya digunakan untuk mengevaluasi model regresi linear. Cara ini juga dikenal dengan nama *root mean squared deviation* (RMSD). Seperti dapat diperkirakan dari namanya, RMSE atau RMSD dihitung dengan menguadratkan eror (peramalan-aktual) dibagi dengan jumlah data (=rata-rata) lalu di akar. Secara matematis terdapat pada persamaan 2.19.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2.19)$$

c. MDA

Mean directional accuracy (MDA) merupakan alat ukur akurasi yang digunakan untuk membandingkan arah data peramalan dan arah data aktual (naik dan turunnya), dengan kata lain bagaimana ketepatan model peramalan dalam mengikuti pola data aktual[29]. Persamaan 2.20 adalah persamaan untuk menentukan MDA.

$$MDA = \sum_t 1_{sign(A_t - A_{t-1}) == sign(F_t - F_{t-1})} \quad (2.20)$$

Dengan catatan:

A = nilai aktual

F = nilai peramalan

2.2.6. ARIMA-NN

Permasalahan yang ditemui di dunia nyata adalah permasalahan data yang tidak stasioner atau tidak linier. Dibutuhkan suatu alat yang akurat dan efektif untuk meramalkan perilaku data yang tidak stasioner atau tidak linier tersebut. Namun terdapat pula permasalahan lain dalam model jaringan syaraf yang sering ditemui yaitu permasalahan overfitting, dimana model yang dibuat hanya menghasilkan output yang baik untuk data yang dilatih saja dan tidak untuk data yang divalidasi (data yang tidak termasuk proses training). Ini adalah fenomena overfitting yang termasuk masalah yang sering ditemui ketika menggunakan model jaringan syaraf.

Di sisi lain, permasalahan tersebut dapat diminimalisir dengan pengembangan yang mengkombinasikannya dengan model lain. Kombinasi yang pernah dicobakan untuk peramalan time series adalah model jaringan syaraf tiruan dengan model Auto Regressive Integrated Moving Average (ARIMA) [22]. Ada tiga hal yang menjadi alasan penggunaan pengkombinasian model ARIMA dan neural network [23]. Pertama, sering kali

terjadi kesulitan untuk menerapkan penggunaan model linier atau model nonlinier pada suatu permasalahan time series, sehingga model kombinasi ini menjadi alternatif yang lebih mudah.

Kedua, dalam kenyataannya time series jarang yang linier atau nonlinier dan sering mengandung keduanya, dimana tidak hanya model ARIMA dan neural network masing-masing dapat memodelkan setiap kasusnya, sehingga pengkombinasian ini dapat digunakan untuk memodelkan time series yang mengandung linier dan nonlinier. Ketiga, dalam beberapa literatur peramalan menyatakan bahwa tidak ada model tunggal yang terbaik pada setiap situasi. ARIMA sering disebut juga metode runtun waktu Box Jenkins. ARIMA cukup dikenal dalam peramalan time series. ARIMA sangat baik ketepatannya untuk peramalan jangka pendek dan untuk data time series non stasioner pada saat linier [24]. Sedangkan untuk data peramalan dalam periode yang cukup panjang ketepatannya kurang baik karena biasanya akan cenderung flat (datar/konstan). Selain itu ARIMA akan mengalami penurunan keakuratan apabila terdapat komponen nonlinier time series pada data pengamatan. Zhang (2003) pun menyatakan bahwa ARIMA tidak mampu memodelkan time series yang nonlinier.

Berbeda dengan ARIMA, model jaringan syaraf (neural network) merupakan metode peramalan yang dapat digunakan untuk memprediksi time series nonlinier, selain itu stasioneritas dari data juga tidak dihiraukan [24]. Padahal dalam kehidupan nyata banyak permasalahan dengan data yang mengandung kelinieran dan ketidak-linieran sekaligus.

Secara umum, pada persamaan 2.21 merupakan kombinasi dari model *time series* yang memiliki struktur autokorelasi linier dan nonlinier.

$$y_t = L_t + N_t \quad (2.21)$$

Dimana:

L_t: Komponen linier

Nt : komponen nonlinier

Dua komponen tersebut digunakan untuk meramalkan data. Pertama, digunakan ARIMA untuk bentuk model linier, kemudian residual dari model linier akan mengandung hubungan nonlinier. Pada persamaan 2.22, et menunjukkan residual saat t waktu dari model linier.

$$et = yt - \hat{L}t \quad (2.22)$$

Dimana:

$\hat{L}t$: Nilai peramalan untuk t waktu dari hubungan penaksiran

Dalam mendiagnosa model-model linier, residual sangat penting sehingga saat memodelkan residual menggunakan ANN, hubungan nonlinier dapat ditemukan. Sehingga persamaan 2.23 merupakan model ANN untuk residual dengan n input.

$$et = f(et-1, et-2, \dots, et-n) + \varepsilon t \quad (2.23)$$

Dimana:

f : fungsi nonlinier yang ditentukan dengan ANN

εt : error

Sehingga pada persamaan 2.24 merupakan rumus dari kombinasi peramalannya.

$$\hat{y}_t = \hat{L}t + \hat{N}t \quad (2.24)$$

Singkatnya, tujuan dari metodologi system hibridasi ARIMA-NN terdiri atas dua langkah. Langkah pertama, model ARIMA digunakan untuk menganalisis masalah bagian linier. Dan langkah kedua, model ANN dibangun untuk memodelkan residual dari model ARIMA. Karena model ARIMA tidak dapat menangkap struktur nonlinier dari data, model residual dari linier akan memiliki informasi tentang nonlinier. Hasil dari

ANN dapat digunakan sebagai meramalkan *error* untuk model ARIMA [30].

Langkah-langkah peramalan dengan metode hibrid ARIMA – NN adalah sebagai berikut:

- a. Melakukan pemodelan dan peramalan menggunakan model ARIMA terbaik.
- b. Setelah diperoleh residual dari model ARIMA, langkah selanjutnya adalah melakukan peramalan residual dari model ARIMA tersebut dengan menggunakan metode jaringan syaraf tiruan.
- c. Hasil peramalan diperoleh dari selisih antara nilai data actual dan hasil peramalan residual menggunakan metode jaringan syaraf tiruan.

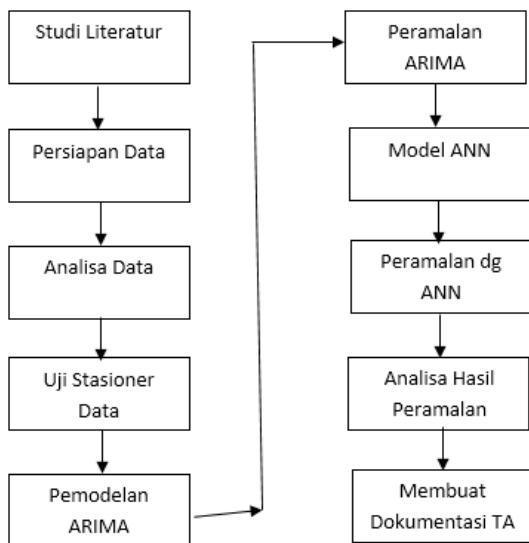
BAB III

METODE PENGERJAAN TUGAS AKHIR

Bab ini berisi tentang metodologi pelaksanaan tugas akhir ini.

3.1. Tahapan pelaksanaan tugas akhir

Gambar 3.1 merupakan diagram metodologi penelitian tugas akhir.



Gambar 3.1 Metodologi Penelitian Tugas Akhir

3.2. Uraian metodologi

Pada sub bab ini akan dijelaskan lebih detail setiap proses yang ada dalam metodologi pelaksanaan tugas akhir ini.

3.2.1. Studi literatur

Studi Literatur merupakan suatu kegiatan penelitian dalam mengumpulkan informasi yang dibutuhkan selama proses

pengerajan tugas akhir. Pengumpulan informasi bisa didapatkan melalui penelitian terdahulu, narasumber, buku, maupun dokumen yang terkait. Studi literatur dilakukan untuk mencari dasar teori yang dapat mendukung dalam penyelesaian topik permasalahan. Adapun konsep yang didapatkan yaitu konsep peramalan, konsep ARIMA, serta model ARIMA-NN dan sebagainya. Sedangkan knowledge gap didapatkan dari hasil-hasil penelitian sebelumnya.

3.2.2. Persiapan Data

Dalam pengerajan tugas akhir ini diperlukan data yang mendukung dan dapat digunakan dalam melaksanakan proses penelitian tugas akhir. Data yang dibutuhkan oleh penulis adalah data yang bersifat intermiten berupa data jumlah impor beras dari tahun 2002 hingga 2016. Dan dalam tahap ini dilakukan uji realibilitas dan validitas terhadap data yang akan digunakan apakah data tersebut layak untuk digunakan dalam melakukan peramalan.

3.2.3. Proses Analisis Model ARIMA

Pada proses ini mulai dilakukan pembentukan model untuk melakukan peramalan.

3.2.3.1. Analisa Data

Melakukan analisa data dengan melakukan pengujian stasioneran data dengan melihat plot data dengan cara melihat grafik yaitu plot ACF dan PACF. Jika data tidak stasioner maka harus dilakukan proses stasioner terlebih dahulu dengan proses differencing atau pembedaan.

3.2.3.2. Uji Stasioner Data

Pada tahap ini data diharuskan stasioner dalam ragam maupun rataan, jika data telah stasioner dalam ragam maupun rataan bias dilanjutkan pada pemodelan ARIMA. Namun jika belum stasioner dalam ragam harus

dilakukan transformasi data, tetapi pada data yang tidak stasioner dalam rataan harus dilakukan differencing data.

3.2.3.3. Pemodelan ARIMA

Apabila data telah stasioner dalam ragam maupun rataan maka tahap selanjutnya adalah pemodelan ARIMA.

3.2.3.3.1. Estimasi Parameter

Dalam melakukan estimasi parameter memiliki dua cara yang mendasar yaitu menggunakan *trial and error* dan perbaikan secara *iterative*. *Trial and error* dilakukan dengan cara menguji beberapa nilai yang berbeda dan memilih satu nilai tersebut (atau sekumpulan nilai, apabila terdapat lebih dari satu parameter yang akan diramalkan) yang meminimumkan jumlah kuadrat nilai sisa (*sum of squared residual*). Pada perbaikan secara *iterative* dilakukan dengan cara memilih taksiran awal dan kemudian membiarkan program komputer memperhalus penaksiran tersebut secara *iterative*.

3.2.3.3.2. Uji Signifikansi Parameter

Tahap ini untuk menguji model yang telah ditentukan pada tahap sebelumnya. Pengujian dilakukan untuk menentukan model layak atau tidak untuk dilanjutkan proses selanjutnya. Model dapat dikatakan layak jika memiliki nilai probabilitas variable $\leq 0,05$.

3.2.3.3.3. Uji Diagnostik Model

Pada tahap ini model akan diuji untuk mengetahui apakah model bersifat acak dan homogen. Ketika model tidak acak dan homogenitas, maka data dikatakan tidak layak.

3.2.3.4. Peramalan ARIMA

Setelah semua tahap dilakukan maka dapat dilakukan peramalan dan penarikan kesimpulan. Peramalan ini sebenarnya merupakan penjabaran dari persamaan berdasarkan koefisien-koefisien yang didapat, sehingga dapat menentukan kondisi di masa yang akan datang.

3.2.4. Model NN

Metode peramalan yang menggunakan NN adalah model yang dibentuk menggunakan algoritma *backpropagation* tersebut dipakai untuk meramalkan data intermiten. Tahapan yang dilakukan sebagai berikut [26]:

3.2.4.1. Pelatihan

Tahap pelatihan ini adalah proses pengenalan dari pola pola data yang telah dinormalisasi dengan tujuan untuk mendapatkan nilai bobot yang dapat memetakan antara data input dengan data target yang diinginkan. Bobot yang dihasilkan dalam tiap putaran dapat diubah dan dilakukan secara berulang-ulang sampai mencapai batas pelatihan. Dalam tahap ini, besarnya parameter yang diberikan secara manual sehingga didapatkan jaringan dengan tingkat pengenalan yang optimal.

Parameter-parameter tersebut meliputi jumlah maksimum iterasi, besarnya kecepatan pembelajaran, besarnya kinerja tujuan atau *goal*, dan jumlah *neuron* pada *hidden layer*. Pelatihan dilakukan dengan algoritma *backpropagation* yang terdiri dari tigas fase, yaitu umpan maju (*feedforward*), propagasi mundur (*backpropagation*) dan pembaruan bobot dan bias. Hasilnya yang didapatkan berupa pembaruan bobot jaringan yang nantinya akan digunakan dalam tahap *testing* jaringan.

3.2.4.2. Pengujian

Setelah dilakukan pelatihan jaringan menggunakan data *training*, akan diperoleh nilai-nilai bobot dan bias terbaik

yang mewakili sistem jaringan. Nilai bobot dan bias baru diterapkan pada data *testing* untuk menghasilkan ramalan data runtun waktu yang diinginkan. Jika jaringan diberikan *input*, maka jaringan akan dapat menghasilkan *output* seperti yang diharapkan. Dengan cara menerapkan algoritma *backpropagation* kembali namun hanya fase *feedforward*. Tahap *testing* dilakukan untuk mengetahui apakah jaringan dapat bekerja dengan baik dalam meramalkan pola data yang telah dilatihkan dengan tingkat kesalahan yang kecil.

3.2.4.3. Peramalan dengan ANN

Model dengan tingkat pengenalan terbaik dalam proses *testing* dapat digunakan untuk proses meramalkan data pada masa yang akan datang. Tujuan dari peramalan ini adalah memperkirakan jumlah permintaan tertentu pada periode berikutnya. Hasil dari data historis diumpulkan ke dalam NN yang telah disimpan dan diolah dengan bobot atau bias tertentu, sehingga didapatkan jumlah penerimaan impor beras menggunakan ANN.

3.2.5. Dokumentasi Tugas Akhir

Setelah dilakukan seluruh tahap maka tahap akhir yang akan dilakukan oleh penulis adalah melakukan dokumentasi berupa buku dari hasil penelitian tugas akhir yang terdiri dari tujuh bab meliputi Pendahuluan, Tinjauan Pustaka, Metode Penggerjaan Tugas Akhir, Perancangan, Implementasi, Hasil dan Pembahasan serta Kesimpulan dan Saran yang telah dijelaskan pada Bab I Pendahuluan Sub-bab 1.7 Sistematika Penulisan.

Halaman ini sengaja dikosongkan

BAB IV

PERANCANGAN

Bab ini berisikan tentang rancangan penelitian tugas akhir yang akan dijalankan. Bab ini berisi proses penggalian kebutuhan, pengumpulan data, persiapan data, serta pengolahan data yang merupakan pembuatan model dan proses peramalan yang dilakukan.

4.1 Persiapan Data

Pada tahap ini akan dilakukan proses pengumpulan data hingga data dapat digunakan dalam penggerjaan tugas akhir ini. Data yang digunakan pada tugas akhir ini adalah data jumlah impor beras yang berada di Jawa Timur.

4.1.1 Pengumpulan Data

Bahan penelitian dalam tugas akhir ini adalah data jumlah impor beras yang berada di Jawa Timur dari Januari 2002 hingga Desember 2016 dalam periode bulanan dengan satuan ton. Data didapatkan dari instansi Divre Jawa Timur.

4.1.2 Pra-proses Data

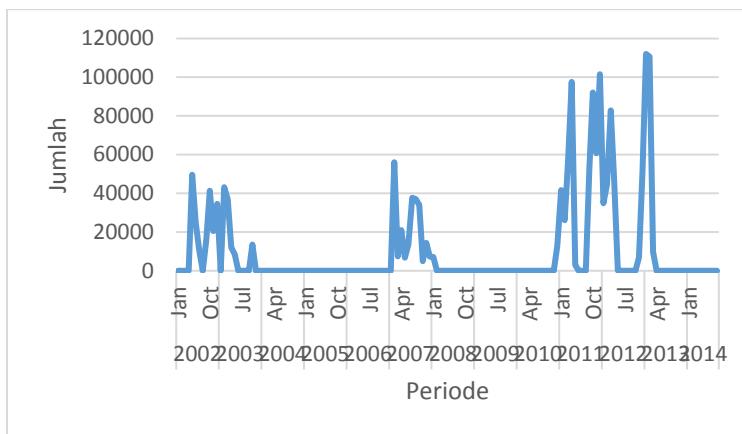
Persiapan data atau pra-proses data dimulai dari melakukan pemisahan data menjadi data pelatihan (*training set*) sebanyak 85% dan data pengujian (*testing set*) sebanyak 15%. Dari keseluruhan data yang berjumlah 180, maka 153 data sebagai data pelatihan dan 27 data sebagai data pengujian. Data jumlah impor beras ini banyak sekali yang bernilai 0.

4.2 Model Penelitian Menggunakan ARIMA

Pada subbab ini dilakukan proses visualisasi data masukan yang akan proses menggunakan metode ARIMA dan tahapan-tahapan metode ARIMA sehingga mendapatkan model yang terbaik.

4.2.1 Gambaran Data Masukan

Gambaran grafik dari data setelah dilakukan pra-proses data dapat dilihat pada Gambar 4.1 yang menunjukkan data jumlah impor beras dalam ton (ton).



Gambar 4.1 Grafik Data Training Jumlah Impor Beras

4.2.2 Uji Stasioner Ragam

Uji stasioner ragam ini dilakukan dengan program Minitab dengan menggunakan fungsi *Box-Cox transformation*. Uji stasioneritas ini dilihat berdasarkan nilai rounded value. Apabila *rounded value* = 1 maka data telah stasioner, namun jika nilai *rounded value* tidak = 1 maka data tidak stasioner dalam ragam maka perlu dilakukan proses transformasi data. Data yang digunakan dalam uji stasioner adalah data jumlah impor beras.

4.2.3 Transformasi Data

Transformasi data ini dilakukan apabila data tidak stasioner dalam ragam. Data yang di transformasi adalah data yang telah diuji pada uji stasioner ragam, yaitu data jumlah impor beras. Transformasi data dapat dilakukan menggunakan *Minitab* menggunakan fungsi *Box-Cox Transformation*.

4.2.4 Uji Stasioner Rataan

Uji stasioner rataan dilakukan untuk mengetahui apakah data telah stasioner dalam rataan atau belum. Uji ini dilakukan menggunakan fungsi *unit root test* pada program *Eviews*. H_0 ditolak apabila menunjukkan bahwa nilai probabilitas $\leq 0,05$ dan juga nilai $|t - \text{statistic}| \geq |\text{test critical values}|$ pada uji akar unit. Sehingga hipotesis yang digunakan yaitu:

H_0 : Terdapat akar unit dan data tidak stasioner

H_1 : Tidak terdapat akar unit dan data stasioner

4.2.5 Differencing Data

Differencing data dilakukan ketika data dinyatakan tidak stasioner terhadap rataan. Proses *differencing* ini menggunakan *unit root test* pada software *Eviews*. Apabila data hasil *differencing* tingkat pertama menggunakan *unit root test* menunjukkan hasil yang tidak stasioner. *Differencing* data dapat dilakukan dua kali atau lebih hingga hasil dinyatakan stasioner.

4.2.6 Pemodelan dan Estimasi Parameter ARIMA

Data yang dilakukan dalam pemodelan ARIMA adalah data yang sudah melalui tahapan transformasi dan *differencing* data. Estimasi parameter dilakukan untuk menentukan model yang digunakan dalam model ARIMA yaitu AR, MA atau ARMA. Selain itu estimasi parameter dilakukan untuk menentukan ordo masing-masing dengan melihat lag ada grafik ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*) dengan menggunakan fungsi *Correlogram* pada *Eviews*.

4.2.7 Uji Signifikansi ARIMA

Tujuan dilakukan uji signifikansi adalah untuk mengetahui kelayakan model ARIMA yang telah ditemukan. Apabila nilai p-value $> 0,05$ dan $|t - \text{statistic}| \text{ seluruh variabel} > t - \text{tabel}$ maka dikatakan lulus uji signifikan. Uji signifikansi ARIMA menggunakan fungsi *Quick Estimation* pada software *Eviews*, dengan ketentuan p adalah ordo

untuk AR dan q untuk ordo MA. Sehingga hipotesis yang digunakan yaitu:

H_0 : Model tidak layak digunakan

H_1 : Model layak digunakan

4.2.8 Uji Diagnostik Parameter ARIMA

Uji diagnostik ini bertujuan untuk mengetahui kelayakan dari model ARIMA melalui residual model. Uji diagnostik parameter dilakukan dengan menggunakan fungsi *Correlogram – Q Statistic* pada program *Eviews*. Model dapat dinyatakan diterima apabila rata-rata seluruh nilai probabilitas $\geq 0,05$. Sedangkan untuk pengujian homogenitas sisaan dilakukan dengan menggunakan fungsi *Correlogram Squared Residuals* pada program *Eviews*. Model dapat dinyatakan diterima dari uji homogenitas sisaan apabila ratarata seluruh nilai probabilitas $\geq 0,05$. Sehingga hipotesis yang digunakan adalah :

H_0 : Model tidak diterima untuk digunakan sebagai model terbaik

H_1 : Model diterima untuk digunakan sebagai model terbaik

4.2.9 Penentuan Model Terbaik ARIMA

Tahapan ini dilakukan ketika pada tahapan sebelumnya didapatkan lebih dari satu model. Penentuan model terbaik dapat dinyatakan diterima apabila melihat nilai AIC dan SIC yang memiliki nilai terkecil.

4.2.10 Uji Akurasi Model Peramalan

Tahapan ini dilakukan setelah mendapatkan model ARIMA terbaik dan telah melakukan peramalan dengan menggunakan data jumlah impor beras. Tujuan dari tahapan ini adalah untuk mengetahui tingkat keakuratan model yang telah didapatkan dalam melakukan peramalan. Untuk menghitung ketepatan model ARIMA dapat dilakukan dengan megukur nilai MAD (*Mean Absolute Deviation*) , RMSE (*Root Mean Squared Error*) dan MDA (*Mean Directional Accuracy*) dengan cara menghitung

perbandingan antara data aktual dengan hasil peramalan menggunakan *Microsoft Excel*.

4.3 Metode ARIMA-NN

Tahap berikutnya adalah melakukan metode *hybrid* dengan menggunakan nilai error yang dihasilkan dari peramalan ARIMA sebelumnya sebagai input ANN yang akan diolah dalam program *Weka*

4.3.1 Pra-proses Data

Data yang digunakan dalam penggerjaan tugas akhir ini adalah data residu yang didapatkan dari hasil peramalan ARIMA. Data yang digunakan dapat dilihat pada LAMPIRAN C.

4.3.2 Perancangan Model ANN

Sebelum melakukan perancangan model maka perlu menyiapkan data untuk pelatihan (*training set*) dan pengujian (*testing set*). Perbandingan data untuk *training set* dan *testing set* adalah sebanyak 85%:15% dengan rincian sebanyak 153 data sebagai data pelatihan dan 27 data sebagai data pengujian.

Rancangan arsitektur ANN yang digunakan dalam tugas akhir ini terdiri atas *input layer*, *hidden layer* dan *output layer* beserta dengan parameter yang akan digunakan dalam proses *training*. *Hidden layer* terdiri atas satu lapisan yang berisi neuron dengan fungsi aktivitas *sigmoid*. Untuk jumlah neuron pada *hidden layer* nya ditentukan pada proses *trial & error*. Pembuatan model Percobaan pencarian model regresi dilakukan dengan cara *stepwise regression*. Untuk pencarian model hanya diwakilkan oleh salah satu provinsi saja. Ketika sudah ditemukan model yang optimal, maka provinsi lain menyesuaikan dengan model provinsi pertama. Data provinsi yang menjadi acuan disini adalah data Provinsi Jawa Barat.

Tabel 4.1 Rancangan Model ANN

Parameter	Jumlah	Deskripsi
Input Layer	N	Berdasarkan hasil dari residu proses ARIMA
Hidden Layer	N sampai 3N	Satu hidden layer dengan beberapa node
Output Layer	1	Data residu ramalan jumlah impor beras
Epoch	Trial and Error	100-500
Learning Rate	Trial and Error	0.1-0.9
Momentum	Trial and Error	0.1-0.9

4.3.3 Peramalan Data

Peramalan menggunakan hybrid ARIMA-NN adalah menggunakan nilai error yang di convert menggunakan *Write Excel*, kemudian akan disimpan dalam *file Excel* baru. Selanjutnya akan dilakukan proses penghitungan untuk menentukan nilai peramalan yang dihasilkan menggunakan metode hybrid ARIMA-NN dengan ketentuan bahwa *Nilai forecast hybrid ARIMA-NN = nilai aktual – (nilai error hybrid ARIMA-NN)*.

4.3.4 Ketepatan Model Peramalan

Ketepatan model peramalan dilakukan dengan tujuan untuk mengetahui tingkat kearutan model yang telah didapatkan dalam melakukan peramalan. Untuk menghitung ketepatan model hybrid ARIMA-NN dilakukan dengan megukur nilai MAD (*Mean Absolute Deviation*), MDA (*Mean Directional Accuracy*) dan RMSE (*Root Mean Square Error*) dengan cara menghitung perbandingan antara data aktual dengan hasil peramalan menggunakan *Microsoft Excel*.

4.3.5 Peramalan Periode Mendatang

Data yang telah diperoleh dan diolah pada *Weka*, selanjutnya di-*import* dan akan disimpan kedalam bentuk *file spreadsheet Excel*, menggunakan operator *Export*. Kemudian melakukan peramalan periode 2017 dan 2018 dengan melakukan prediksi dari data ramalan yang dilakukan di *Microsoft Excel* serta menghitung akurasi hasil peramalannya menggunakan MAD, RMSE dan MDA.

Halaman ini sengaja dikosongkan

BAB V

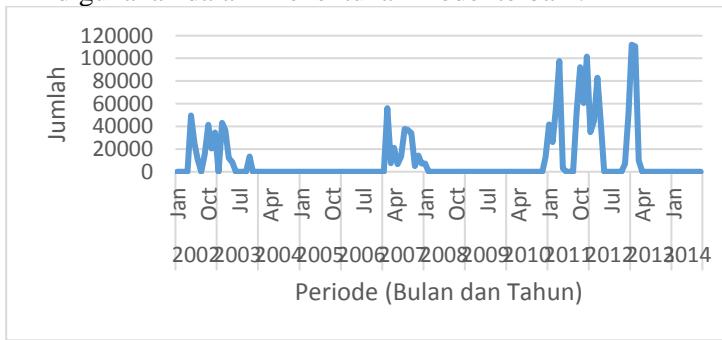
IMPLEMENTASI

Bab ini menjelaskan proses pelaksanaan penelitian dan pembuatan model yang akan digunakan untuk peramalan.

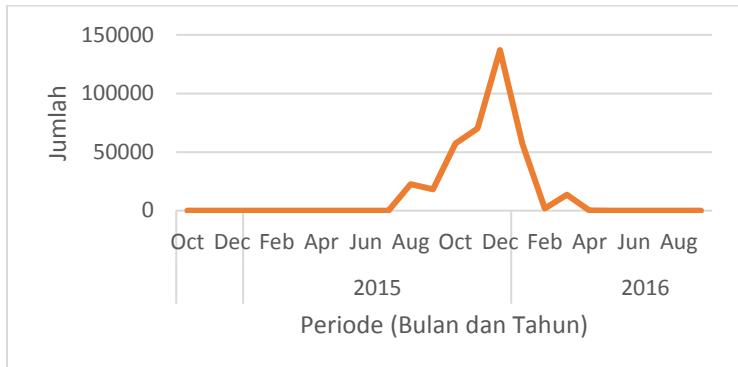
5.1 Implementasi Model ARIMA

5.1.1 Menentukan Training Set dan Testing Set

Pada penelitian ini, data yang digunakan dalam pemodelan dibagi menjadi dua yaitu data pelatihan dan pengujian. 85% data pelatihan atau *training set* dan 15% data pengujian atau *testing set*. Data pelatihan digunakan untuk model peramalan dan data pengujian digunakan untuk menguji model yang didapatkan. Berdasarkan data observasi, didapatkan data bulanan sejak bulan Januari 2000- Desember 2016. Data sebanyak 153 data (Januari 2000 – September 2014) merupakan data pelatihan 27 data (Oktober 2014-Desember 2016) merupakan data pengujian. Gambar 5.1 adalah grafik dari data training dan Gambar 5.2 adalah grafik dari data testing yang akan digunakan dalam menentukan model terbaik.



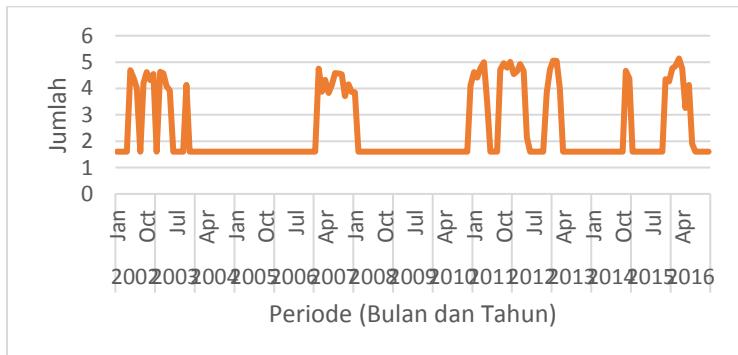
Gambar 5.1 Grafik Data Training



Gambar 5.2 Grafik Data Testing

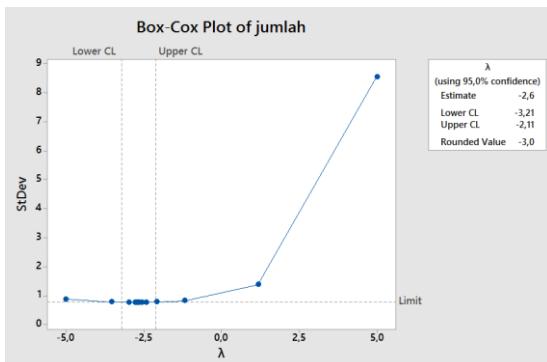
5.1.2 Uji Stasioner Ragam

Uji stasioner ragam dilakukan pada data jumlah impor beras dengan menggunakan tools Minitab. Namun karena data banyak yang bernilai 0, maka dilakukan transformasi dahulu sebelum di uji stasioneritas. Transformasinya menggunakan *Microsoft Excel* dengan rumus **$x=\log(\text{data aktual} + \text{nilai data terendah setelah } 0)$** . Gambar 5.3 merupakan grafik hasil transformasi data awal sebelum dilakukan uji stasioner ragam dengan data aktual.



Gambar 5.3 Grafik Data Transformasi Awal Jumlah Impor Beras

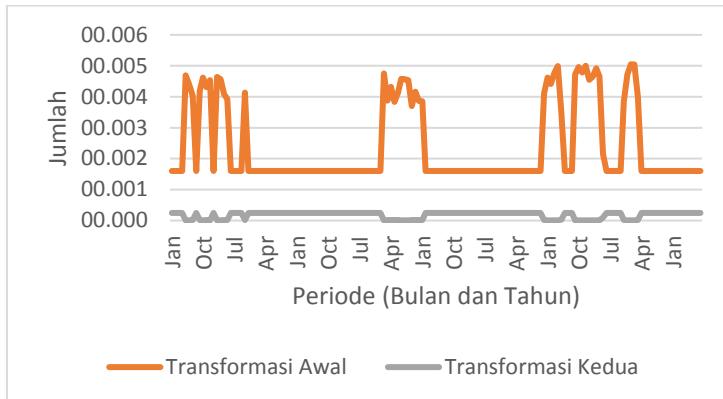
Selanjutnya adalah melakukan uji stasioner ragam dengan menggunakan data yang sudah dilakukan transformasi awal pada Gambar 5.3 tersebut. Software yang digunakan adalah *Minitab* dengan fungsi *Box-Cox Transformation*. Pada Gambar 5.4 menunjukkan hasil dari uji stasioner ragam yang memiliki nilai *rounded value* -3.00 . Suatu data dikatakan stasioner dalam ragam apabila memiliki *rounded value* = 1. Dikarenakan data tidak stasioner dalam ragam, maka perlu dilakukan transformasi data lagi dalam tahapan selanjutnya.



Gambar 5.4 Hasil Uji Stasioner Ragam

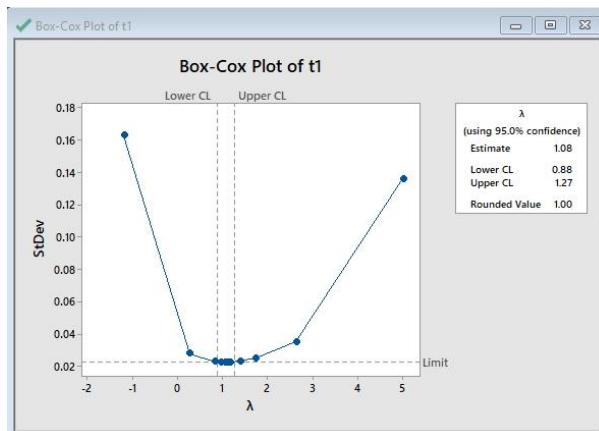
5.1.3 Tranformasi Data

Transformasi dilakukan terhadap data jumlah impor beras menggunakan fungsi *Box-Cox Transformation* pada Minitab untuk mendapatkan *rounded value* = 1. Gambar 5.5 merupakan grafik perbandingan dari hasil transformasi awal data dengan grafik hasil transformasi kedua. Transformasi data dilakukan pada data jumlah impor beras karena hasil uji menyatakan data tidak stasioner dalam ragam.



Gambar 5.5 Grafik Perbandingan Transformasi

Untuk membuktikan bahwa data sesudah di transformasi kedua telah stasioner dalam ragam, maka dilakukan uji stasioner ragam kembali menggunakan fungsi *Box-Cox Transformation* pada Minitab. Dan sudah terbukti pada Gambar 5.6 bahwa rounded value data = 1, sehingga dapat dikatakan bahwa data hasil transformasi tersebut telah stasioner dalam ragam.



Gambar 5.6 Hasil Uji Stasioner Ragam Kedua

Selanjutnya adalah memindahkan data hasil transformasi kedua dari Minitab ke *Microsoft Excel* untuk dilakukan proses selanjutnya pada *Eviews*. Data hasil transformasi kedua akan dicantumkan pada LAMPIRAN A.

5.1.4 Uji Stasioner Rataan

Uji stasioner rataan dilakukan pada data jumlah impor beras di Jawa Timur. Uji stasioner rataan dilakukan dengan *Eviews*, dan penilaian stasioneritas data didasarkan pada nilai probabilitas dan t-statistic. Data dikatakan telah stasioner jika nilai probabilitas $\leq 0,05$ dan $|t\text{-statistic}| > |t\text{-critical value}|$. Jika data belum stasioner, maka dilakukan differencing data. Gambar 5.7 menunjukkan hasil uji *Unit Root Test* yang dilakukan pada *Eviews*.

Augmented Dickey-Fuller Unit Root Test on JUMLAH1		
Null Hypothesis: JUMLAH1 has a unit root		
Exogenous: Constant, Linear Trend		
Lag Length: 0 (Automatic - based on SIC, maxlag=13)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.495336	0.0021
Test critical values:		
1% level	-4.019561	
5% level	-3.439658	
10% level	-3.144229	

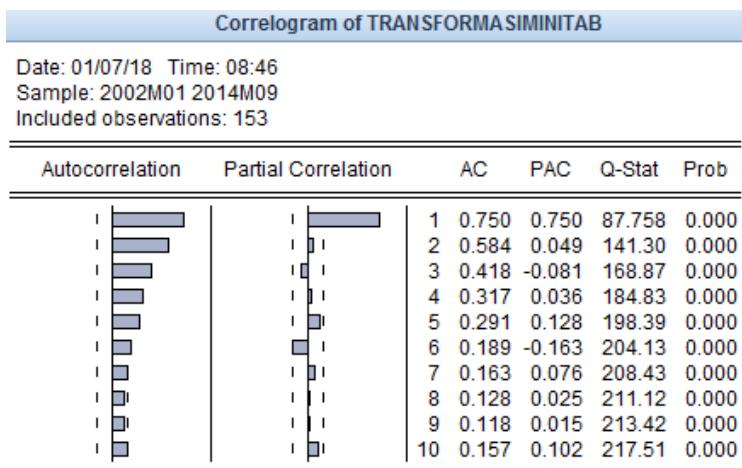
*MacKinnon (1996) one-sided p-values.

Gambar 5.7 Hasil Uji Stasioner Rataan

Dari hasil uji stasioneritas rataan pada Gambar 5.7 menunjukkan bahwa nilai probabilitas 0,0015 atau $< 0,05$ dan $|t\text{-statistic}| > |test\text{ critical values}|$ yang berarti H_0 yang disebutkan di sub bab 4.2.4 ditolak.. Berdasarkan hasil tersebut, maka data jumlah impor beras belum stasioner dalam rataan. Sehingga langkah selanjutnya adalah melakukan estimasi parameter tanpa melakukan differencing data.

5.1.5 Estimasi Parameter

Estimasi parameter ARIMA dilakukan dengan melihat grafik *correlogram ACF* dan *PACF* pada software *Eviews*. Jumlah ordo pada model *Autoregressive* (AR) didapatkan dari grafik PACF, sedangkan jumlah ordo pada model *Moving Average* (MA) didapatkan pada grafik ACF. Grafik ACF dan PACF dari hasil estimasi parameter data impor beras dicantukan terdapat pada Gambar 5.7.



Gambar 5.8 Hasil Correlogram untuk Transformasi Data

Dari hasil Gambar 5.8 tersebut, maka dapat disimpulkan bahwa AR memiliki ordo 2 dan MA memiliki ordo 6 pada lag 10. Tabel 5.1 merupakan daftar estimasi parameter yang akan digunakan untuk menemukan model ARIMA terbaik.

Tabel 5.1 Daftar Estimasi Parameter

Variabel	Model ARIMA
Jumlah Impor Beras	ARIMA(0,0,1); ARIMA (0,0,2); ARIMA (0,0,3); ARIMA (0,0,4); ARIMA (0,0,5); ARIMA (0,0,6); ARIMA (1,0,0); ARIMA (1,0,1);

Variabel	Model ARIMA
	ARIMA (1,0,2); ARIMA (1,0,3); ARIMA (1,0,4); ARIMA (1,0,5); ARIMA (1,0,6); ARIMA (2,0,0); ARIMA (2,0,1); ARIMA (2,0,2); ARIMA (2,0,3); ARIMA (2,0,4); ARIMA (2,0,5); ARIMA (2,0,6);

5.1.6 Uji Signifikansi Model

Seluruh model ARIMA yang didapatkan dari tahap sebelumnya akan dilakukan uji signifikansi dengan melihat nilai probabilitas model. Jika nilai probabilitas seluruh variabel ≤ 0.05 dan $|t\text{-statistic}| > t\text{-tabel}$, maka model dikatakan signifikan dan dapat dilakukan uji diagnosa.

```
Dependent Variable: TRANSFORMASIMINITAB
Method: ARMA Maximum Likelihood (OPG - BHHH)
Date: 01/07/18 Time: 09:07
Sample: 2002M01 2014M09
Included observations: 153
Convergence achieved after 18 iterations
Coefficient covariance computed using outer product of gradients
```

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.938734	0.043441	21.60958	0.0000
SIGMASQ	0.005345	0.000397	13.45087	0.0000
R-squared	0.516649	Mean dependent var		0.180020
Adjusted R-squared	0.513448	S.D. dependent var		0.105507
S.E. of regression	0.073594	Akaike info criterion		-2.353586
Sum squared resid	0.817836	Schwarz criterion		-2.313973
Log likelihood	182.0494	Hannan-Quinn criter.		-2.337495
Durbin-Watson stat	2.257479			
Inverted AR Roots	.94			

Gambar 5.9 Hasil Uji Signifikansi Model ARIMA (1,0,0)

Hasil uji signifikansi pada Gambar 5.9 menunjukkan bahwa parameter telah signifikan karena nilai probabilitas variable ≤ 0.05 dan $|t\text{-statistic}| > t\text{-tabel}$ yang berarti H_0 yang disebutkan di sub bab 4.2.7

ditolak. T-tabel untuk seluruh uji signifikansi parameter adalah 1,98. Seluruh hasil uji signifikansi setiap parameter terdapat dalam LAMPIRAN B dan telah dirangkum dalam Tabel 5.2.

Hasil uji signifikansi model secara rinci dicantumkan pada LAMPIRAN B. Pada uji signifikansi terdapat dua status antara lain lolos dan tidak lolos. Model ARIMA dengan status lolos dilanjutkan ke tahapan diagnose.

Tabel 5.2 Hasil Uji Signifikansi Model ARIMA

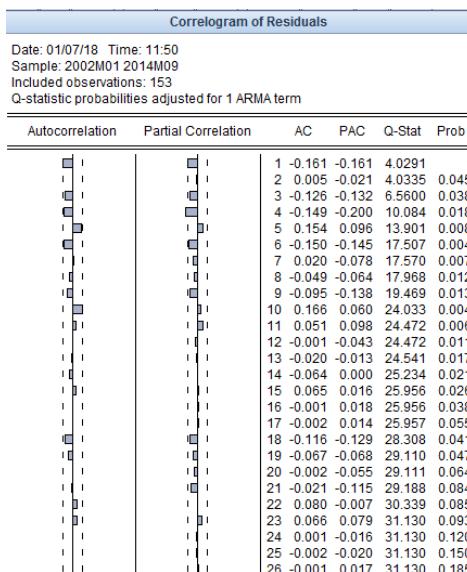
Variabel	Model ARIMA	Keterangan
Jumlah Impor Beras	(0,0,1)	Lolos
	(0,0,2)	Lolos
	(0,0,3)	Lolos
	(0,0,4)	Lolos
	(0,0,5)	Lolos
	(0,0,6)	Lolos
	(1,0,0)	Lolos
	(1,0,1)	Tidak Lolos
	(1,0,2)	Tidak Lolos
	(1,0,3)	Tidak Lolos
	(1,0,4)	Tidak Lolos
	(1,0,5)	Lolos
	(1,0,6)	Tidak Lolos
	(2,0,0)	Lolos
	(2,0,1)	Lolos
	(2,0,2)	Tidak Lolos
	(2,0,3)	Tidak Lolos
	(2,0,4)	Tidak Lolos
	(2,0,5)	Tidak Lolos
	(2,0,6)	Tidak Lolos

Dari tabel 5.2, model ARIMA yang lolos uji signifikansi adalah ARIMA (0,0,1) , ARIMA (0,0,2), ARIMA (0,0,3), ARIMA (0,0,4), ARIMA (0,0,5), ARIMA (0,0,6), ARIMA (1,0,0), ARIMA (1,0,5), ARIMA (2,0,0), ARIMA (2,0,1). Sehingga 10 model tersebut akan dilanjutkan ke tahap berikutnya yaitu uji diagnostik parameter.

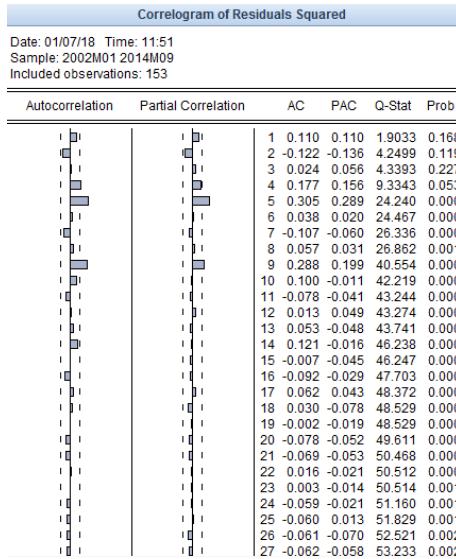
5.1.7 Uji Diagnostik Parameter

Uji diagnosa model ARIMA dilakukan untuk menguji kelayakan model dari residual atau sisaan. Uji diagnosa dilakukan dengan menggunakan *Eviews*. Model statistic dikatakan layak apabila pada uji *correlogram Q-statistic* dengan nilai probabilitas $> 0,05$ yang menunjukkan sisaan bersifat acak dan *correlogram – squared residuals* dengan nilai probabilitas $> 0,05$ yang menunjukkan sisaan bersifat homogen yang berarti H_0 yang disebutkan di sub bab 4.2.8 ditolak.

Hasil pada Gambar 5.10 rata-rata nilai probabilitas $> 0,05$ yang menunjukkan model pada ARIMA (1,0,0) bersifat acak. Sedangkan pada Gambar 5.11 rata-rata nilai probabilitas $> 0,05$ yang menunjukkan sisaan model pada ARIMA (1,0,0) bersifat homogen.



Gambar 5.10 Uji Keacakan Sisaan Model ARIMA (1,0,0)



Gambar 5.11 Uji Homogenitas Model ARIMA (1,0,0)

Pada Tabel 5.3 telah dirangkum dari hasil uji diagnostik homogenitas pada data jumlah impor beras.

Tabel 5.3 Uji Diagnostik ARIMA pada Jumlah Impor Beras

Model ARIMA	Uji Keacakan Sisaan	Uji Homogenitas	Keterangan
(0,0,1)	0	0,0205	Tidak Lolos
(0,0,2)	0	0,336	Tidak Lolos
(0,0,3)	0	0	Tidak Lolos
(0,0,4)	0	0	Tidak Lolos
(0,0,5)	0	0	Tidak Lolos
(0,0,6)	0	0	Tidak Lolos
(1,0,0)	0,05	0,0895	Lolos
(1,0,5)	0,833	0,2465	Lolos
(2,0,0)	0	0,0035	Tidak Lolos
(2,0,1)	0,552	0,094	Lolos

Dari tabel 5.3, model ARIMA yang lolos uji diagnostik parameter adalah ARIMA (1,0,0), ARIMA (1,0,5), dan ARIMA (2,0,1). Sehingga 3 model tersebut akan

dilanjutkan ke tahap berikutnya pemilihan model terbaik ARIMA sementara.

5.1.8 Pemilihan Model Terbaik ARIMA Sementara
 Pemilihan model ARIMA dilakukan karena terdapat lebih dari satu model ARIMA yang lulus uji diagnostik. Pemilihan model dilakukan dengan memilih nilai terkecil *Akaike Information Criterion* (AIC) dan *Schwarz Information Criterion* (SIC) dengan menggunakan *Eviews*. Tabel 5.4 menunjukkan daftar nilai AIC dari model ARIMA yang telah lolos diagnostik parameter. Suatu model ARIMA dikatakan dipilih sebagai model terbaik ketika nilai AIC dan SIC terkecil diantara model yang lainnya.

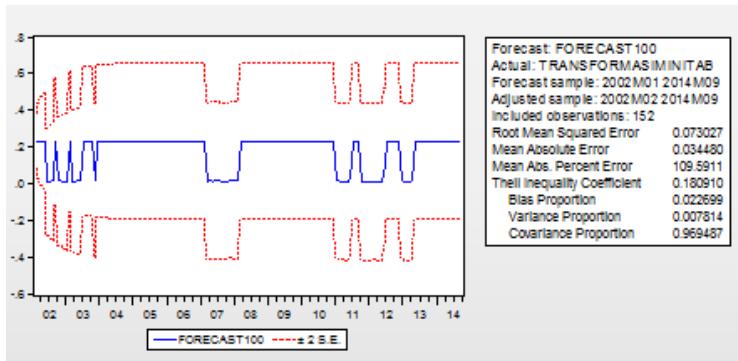
Tabel 5.4 Daftar Nilai AIC dan SIC pada Model ARIMA Sementara

Model ARIMA	AIC	SIC
(1,0,0)	-2,353586	-2,313973
(1,0,5)	-2,364851	-2,305431
(2,0,1)	-2,340967	-2,281546

Pada Tabel 5.4 menunjukkan bahwa nilai AIC dan SIC terkecil terdapat pada model ARIMA (1,0,0), sehingga untuk peramalan periode 2017-2018 sementara menggunakan model terbaik yaitu ARIMA (1,0,0).

5.1.9 Peramalan Model Terbaik

Setelah menemukan model terbaik, maka selanjutnya adalah melakukan peramalan dengan *Eviews* menggunakan data transformasi kedua. Dan Gambar 5.12 menunjukkan grafik hasil peramalan model terbaik dengan nilai RMSE 0,073027; MAE 0,034480 ; dan MAPE 109,5911.



Gambar 5.12 Hasil Peramalan Model Terbaik pada Data Transformasi Kedua

5.2 Implementasi Model ARIMA-NN

Setelah model ARIMA sudah diramalkan dan mendapat data residiu, maka langkah selanjutnya adalah dilakukan proses peramalan menggunakan ANN.

5.2.1 Pemrosesan Data

Dalam proses pengolahan data, pengerajan tugas akhir ini membagi data seperti metode ARIMA sebelumnya. Pada tahap ini, data akan dikelompokkan menjadi data pelatihan dan data pengujian dengan proporsi 85:15. Total data yang ada adalah 180 data, sehingga data yang akan digunakan sebagai data pelatihan sejumlah 153 data (Januari 2002 – September 2014), data yang digunakan untuk pengujian pertama sejumlah 27 data (Oktober 2014 – Desember 2016).

Tabel 5.5 merupakan inputan ANN yang dihasilkan dari data residiu proses ARIMA, input ANN akan diperoses untuk ARIMA-NN. Dan Tabel 5.6 merupakan data testing yang akan digunakan untuk uji coba hasil ANN yang telah didapatkan.

Tabel 5.5 Data Training Jumlah Impor Beras

Bulan	Data Residual
Januari 2002	0
Februari 2002	0.015112
Maret 2002	0.015112
April 2002	0.015112
Mei 2002	-0.22144
.....
September 2014	0.015112

Tabel 5.6 Data Testing Jumlah Impor Beras

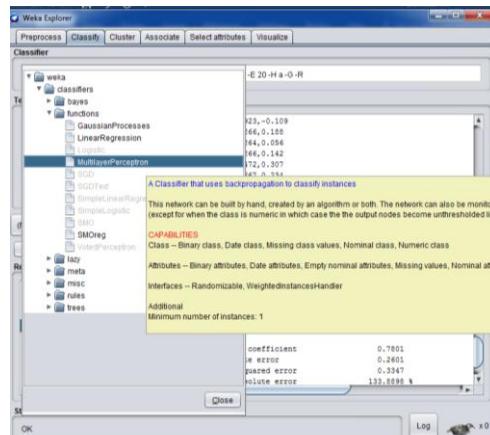
Bulan	Data Residual
Oktober 2014	0
Nopember 2014	-0.21504
Desember 2014	0.003105
Januari 2015	0.235218
Februari 2015	0.02131
.....
Desember 2016	0.02131

Data residual yang telah masuk dalam file excel baru dimasukkan dalam proses pada *Weka* untuk dilakukan preproses data, agar data dapat di proses ke tahapan selanjutnya. Gambar 5.13 adalah tampilan dari tab preproses data pada *Weka*.



Gambar 5.13 Tab Preprocess pada Weka

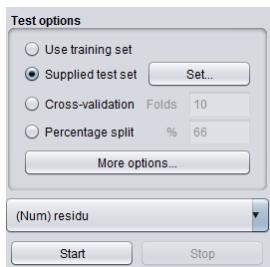
Setelah data dimasukkan, maka proses selanjutnya yaitu menggunakan operator *Classify* seperti pada Gambar 5.14. Toolbars ini digunakan untuk melakukan klasifikasi data sesuai dengan fungsi yang diinginkan. Karena pada tahapan ini akan dilakukan proses ANN, maka menggunakan fungsi *Multilayer Perceptron*.



Gambar 5.14 Fungsi Multilayer Perceptron

5.2.2 Uji Validasi Data

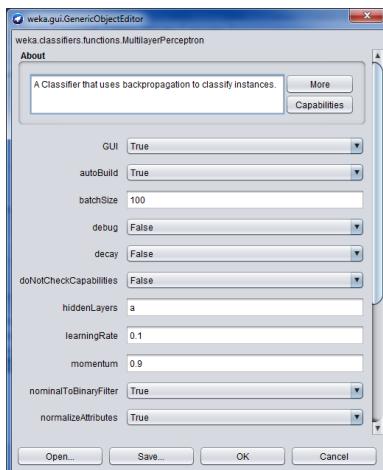
Pada uji validasi data mempunyai 2 sub-proses, yaitu sub-proses *training* dan sub-proses *testing*. Sub-proses *training* digunakan untuk pelatihan sebuah model. Model yang telah ditraining lalu diterapkan didalam sub-proses *testing*. Kinerja model juga diukur selama fase *testing*. Gambar 5.15 adalah fungsi *Test Options* yang digunakan pada program Weka. Pada menu *Use Training Set* digunakan untuk uji data training dan *Supplied test set* digunakan untuk melakukan uji testing.



Gambar 5.15 Menu Test Options

5.2.3 Perancangan Artificial Neural Network

Selanjutnya adalah merancang model ANN sesuai dengan rancangan yang ada pada Tabel 4.1 dengan mengubah jumlah *epoch*, jumlah *hidden layer*, *nodes*, *momentum* dan *learning rate* untuk mencari model terbaik dengan error terkecil. Gambar 5.16 merupakan *dialog box* yang akan digunakan untuk mengatur jumlah *epoch*, jumlah *hidden layer*, *nodes*, *momentum* dan *learning rate*.



Gambar 5.16 Weka GUI Generate Editor

5.2.4 Menentukan Parameter Artificial Neural Network
 Parameter yang diatur selanjutnya pada penggerjaan tugas akhir ini adalah *training*, *cycles*, *learning rate*, dan *momentum* seperti Gambar 5. 16. Untuk parameter awal digunakan 100 hingga 500 *training cycles*, 0,1 hingga 0,9 *learning rate* dan 0,1 hingga 0,9 untuk *momentum* pada satu hidden layer yang jumlah node-nya *automatically* dari sistem.

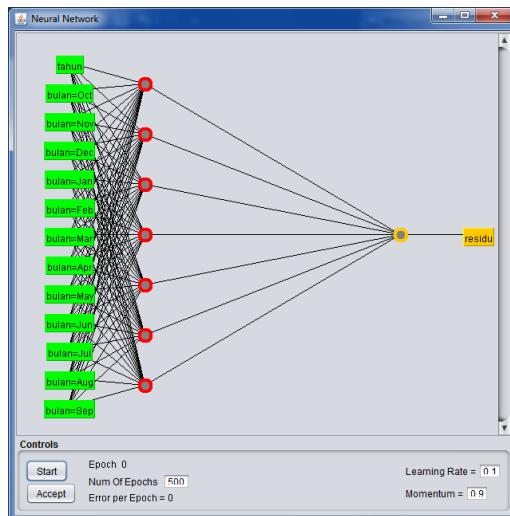
Tabel 5.7 adalah hasil dari *trial and error* pada jumlah epoch, *momentum* dan *learning rate* untuk mendapatkan model terbaik dengan menemukan nilai error terendah. Untuk hasil *trial and error* yang lebih lengkap akan dicantumkan pada LAMPIRAN.

Tabel 5.7 Hasil Trial and Error pada Epoch, Momentum dan Learning Rate

EPOCH	LEARNING RATE	MOMENTUM	RMSE	MSE
500	0.1	0.9	0.2302	0.1437
500	0.7	0.9	0.3078	0.1324
400	0.1	0.9	0.2549	0.1771
400	0.7	0.9	0.3078	0.1324
300	0.1	0.8	0.27	0.1718

EPOCH	LEARNING RATE	MOMENTUM	RMSE	MSE
300	0.7	0.9	0.3078	0.1324
200	0.1	0.8	0.2798	0.1856
200	0.7	0.9	0.3078	0.1324
100	0.3	0.2	0.2826	0.1808
100	0.7	0.9	0.3078	0.1324

Pemilihan parameter ANN terbaik berdasarkan pada parameter dengan nilai RMSE terkecil. Dari Tabel 5.7 maka didapatkan hasil model ANN terbaik dengan RMSE terkecil adalah pada jumlah *epoch* 500, *learning rate* 0,1 , dan *momentum* 0,9. Serta Gambar 5.17 adalah arsitektur ANN yang di dapatkan.



Gambar 5.17 Arsitektur ANN

5.2.5 Penerapan Model Artificial Neural Network

Setelah semua parameter dalam operator telah diatur, selanjutnya menerapkan model ANN untuk diketahui error yang terjadi. Gambar 5.18 adalah contoh dari hasil penerapan model ANN.

```
    === Evaluation on training set ===  
    Time taken to test model on training data: 0.01 seconds  
  
    === Summary ===  
  
    Correlation coefficient           0.4161  
    Mean absolute error              0.1886  
    Root mean squared error          0.3748  
    Relative absolute error          97.0913 %  
    Root relative squared error     100.3165 %  
    Total Number of Instances        27
```

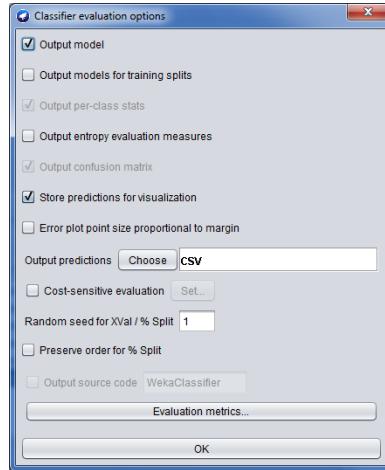
Gambar 5.18 Summary Apply Model

5.2.6 Pengujian

Setelah menemukan model ANN dengan error yang paling kecil, maka model tersebut digunakan untuk melakukan uji pada data testing menggunakan fungsi *Supplied test set* pada *test options* (pada Gambar 5.15) dengan mengimport file yang digunakan sebagai data *testing*.

5.2.7 Peramalan Periode Kedepan

Data yang telah melalui proses ANN akan masuk dalam menu *More Options... > Output Prediction*> pilih CSV, seperti pada Gambar 5.19 yang berfungsi untuk memasukkan nilai atau hasil dari ANN kedalam bentuk CSV. Data dalam format CSV seperti pada gambar 5.20. Setelah data masuk pada summary maka dicopy kedalam *Excel* maka selanjutnya dilakukan proses pengembalian nilai untuk mendapatkan hasil ramalan untuk periode mendatang. Hasil peramalan yang lebih lengkap akan dicantumkan pada LAMPIRAN.



Gambar 5.19 Classifier evaluation options

```
==== Predictions on training set ====
inst#,actual,predicted,error
1,?, -1.763,?
2,0.032,0.172,0.14
3,0.032,0.415,0.384
4,0.032,0.31,0.278
5,1.107,0.9,-0.208
6,0.038,0.16,0.122
7,0.012,0.215,0.203
8,-0.828,-0.459,0.369
9,0.996,1.029,0.033
10,0.191,0.478,0.286
11,0.035,0.055,0.02
12,0.15,0.212,0.062
13,-0.939,-0.6,0.339
14,1.094,0.9,-0.194
15,0.089,0.44,0.351
16,-0.01,0.211,0.221
17,0.057,0.411,0.354
18,-0.805,0.151,0.956
19,0.032,0.167,0.136
20,0.032,0.019,-0.013
21,0.032,0.534,0.502
22,0.979,0.853,-0.126
23,-0.852,0.128,0.98
24,0.032,0.17,0.138
25,0.032,0,-0.031
```

Gambar 5.20 Hasil Peramalan Model ANN

Halaman ini sengaja dikosongkan

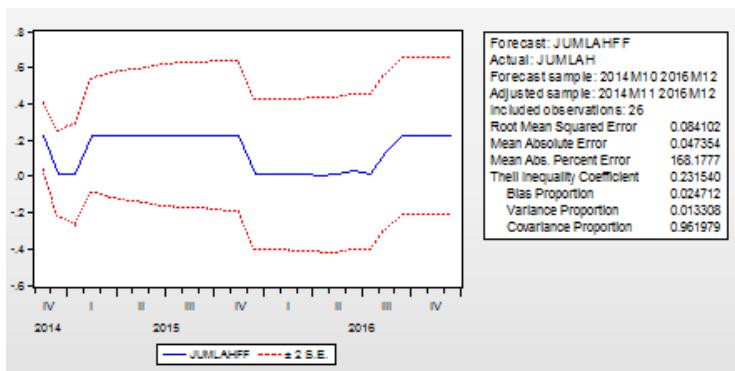
BAB VI

HASIL DAN PEMBAHASAN

Bab ini menjelaskan tentang hasil dan pembahasan setelah melakukan perancangan dan implementasi. Hasil yang akan dijelaskan adalah hasil uji coba model, validasi model, dan hasil peramalan untuk periode yang akan datang.

6.1 Hasil Uji Coba Model ARIMA

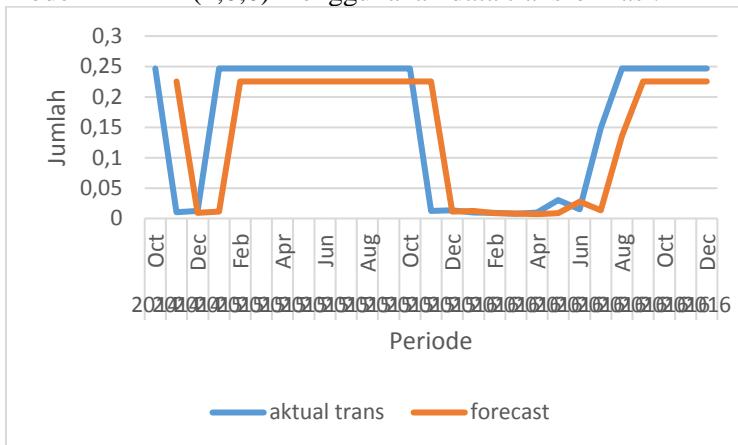
Pada tahap ini, uji coba model dilakukan dengan menggunakan *testing set*. Data yang digunakan masih merupakan data transformasi. Gambar 6.1 merupakan hasil peramalan dengan model ARIMA (1,0,0) menggunakan *testing set* yang dilakukan menggunakan *Eviews*. Data transformasi (*training* dan *testing*) yang sudah dilakukan peramalan pada *Eviews* akan dicantumkan pada LAMPIRAN.



Gambar 6.1 Hasil Peramalan Uji Coba Model ARIMA pada Testing Set (Data Transformasi)

Pada Tabel 6. 1 didapatkan bahwa MAPE sebesar 168,177 pada uji coba untuk data *testing*. Hal tersebut dapat diartikan bahwa model yang dihasilkan memiliki kemampuan yang kurang baik.

Pada Gambar 6.2 menunjukkan grafik perbandingan pada *testing set* antara data aktual dan data ramalan menggunakan model ARIMA (1,0,0) menggunakan data transformasi.



Gambar 6.2 Perbandingan Data Aktual dan Peramalan

Tabel 6.1 menunjukkan hasil pengukuran kinerja model dengan menggunakan nilai MAD, RMSE dan MDA. Nilai validasi tersebut untuk *training set* dan *testing set* pada data transformasi yang dicantumkan dalam satu table dengan tujuan sebagai perbandingan.

Tabel 6.1 Perbandingan Hasil Uji Coba Model ARIMA

Data Set	MAD	RMSE	MDA
Training	0,034255	0,072788	0,802632
Testing	0,008047	0,03467	0,947368

Pada Tabel 6.1 didapatkan bahwa MAD pada uji coba didapatkan < 10% dan nilai RMSE <10%. Hal tersebut dapat dikatakan bahwa model yang dihasilkan ARIMA (1,0,0) memiliki kemampuan yang cukup baik. Dan memiliki tingkat kenaikan dan turunnya data mendekati 100%, yang dapat dikatakan bahwa model yang dihasilkan baik.

6.2 Hasil Uji Coba Parameter Model ANN

Hasil uji coba dilakukan pada data *training* dan data *testing* sebagai validasi model yang telah ditemukan menggunakan tools *Weka* dan untuk menemukan data peramalannya.

Penentuan hidden layer terbaik untuk penentuan model ANN dimulai dari N hingga 3N, dimana N adalah jumlah node pada input layer. Untuk hasil percobaan hidden layer akan dicantumkan pada LAMPIRAN.

Pada tabel 6.2 akan didaftarkan mengenai parameter yang sudah diterapkan pada model ANN terbaik sesuai dengan ketentuan di Tabel 4.1.

Tabel 6.2 Daftar Parameter Model ANN

Parameter	Jumlah
Input Layer	1 input dengan 12 node
Hidden Layer	1 dengan 23 node
Output Layer	1 dengan 1 node
Epoch	500
Learning Rate	0,1
Momentum	0,9

Sehingga untuk melakukan prediksi, yang digunakan adalah pada *learning rate* 0,1 dan *momentum* 0,9 dengan epoch 500 karena memiliki nilai RMSE paling kecil pada data training yaitu 0,0553.

Gambar 6.3 adalah summary dari hasil *multilayer perceptron* data *training* dan Gambar 6.4 summary pada data *testing*.

==== Summary ===

Correlation coefficient	0.6505
Mean absolute error	0.0327
Root mean squared error	0.0553
Relative absolute error	114.1836 %
Root relative squared error	76.5994 %

Gambar 6.3 Summary ANN pada Data Training

```
==== Summary ===
```

Correlation coefficient	0.8964
Mean absolute error	0.0344
Root mean squared error	0.0465
Relative absolute error	80.6784 %
Root relative squared error	55.9638 %

Gambar 6.4 Summary ANN pada Data Testing

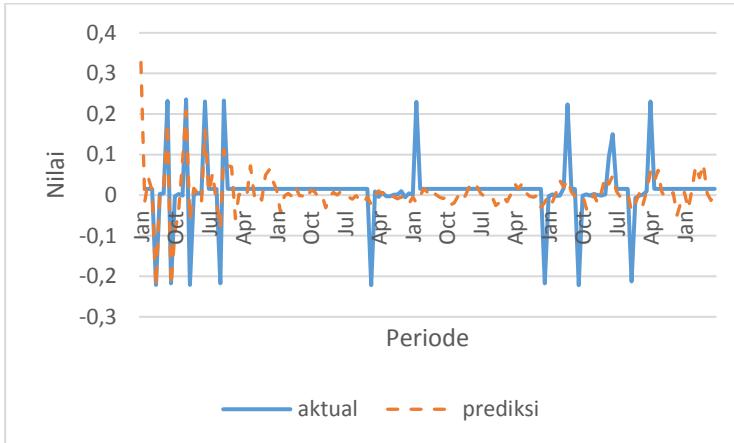
Tabel 6.3 menunjukkan hasil pengukuran kinerja model ANN dengan menggunakan nilai MAD, RMSE dan MDA. Nilai validasi tersebut untuk *training set* dan *testing set* pada data transformasi yang dicantumkan dalam satu table dengan tujuan sebagai perbandingan.

Tabel 6.3 Perbandingan Hasil Uji Coba Model ANN

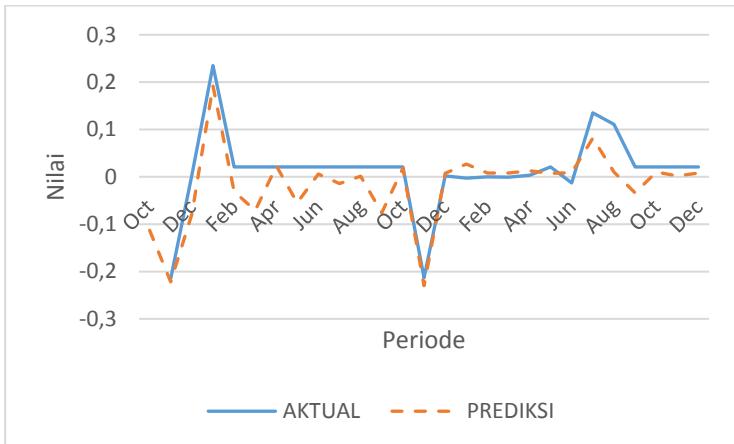
Data Set	MAD	RMSE	MDA
Training	5.304	0.756224	53.3%
Testing	1.009	0.262878	61,5%

Pada Tabel 6.3 didapatkan bahwa MAD pada uji coba didapatkan $< 10\%$ dan nilai RMSE $< 10\%$. Hal tersebut dapat dikatakan bahwa model yang dihasilkan ANN (12,23,1) memiliki kemampuan yang cukup baik dengan memiliki tingkat kenaikan dan turunnya data $< 100\%$, yang dapat dikatakan bahwa model yang dihasilkan cukup baik.

Dari Gambar 6.3, ketika model ANN memiliki nilai RMSE terkecil berarti memungkinkan untuk digunakan sebagai model pada *testing set* dan peramalan periode kedepan. Grafik pada Gambar 6.5 merupakan perbandingan antara data *training* (hasil transformasi) dan peramalan yang telah dilakukan pengujian terhadap model ANN terbaik. Dan Gambar 6.6 merupakan grafik perbandingan antara data *testing* (hasil transformasi) dengan peramalannya.



Gambar 6.5 Perbandingan Data Aktual (Training) dan Peramalan dengan Model ANN

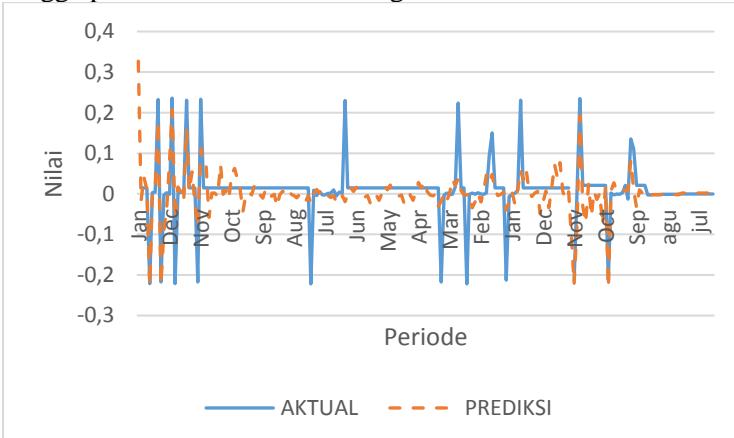


Gambar 6.6 Perbandingan Data Aktual (Testing) dan Peramalan dengan Model ANN

6.3 Analisis Hasil Peramalan ARIMA-NN

Peramalan dilakukan pada seluruh data yang dimiliki. Analisis hasil peramalan dilakukan dengan membandingkan data aktual dan hasil peramalan, sehingga didapatkan nilai kesalahan (MAD, RMSE dan MDA). Data hasil peramalan jumlah impor

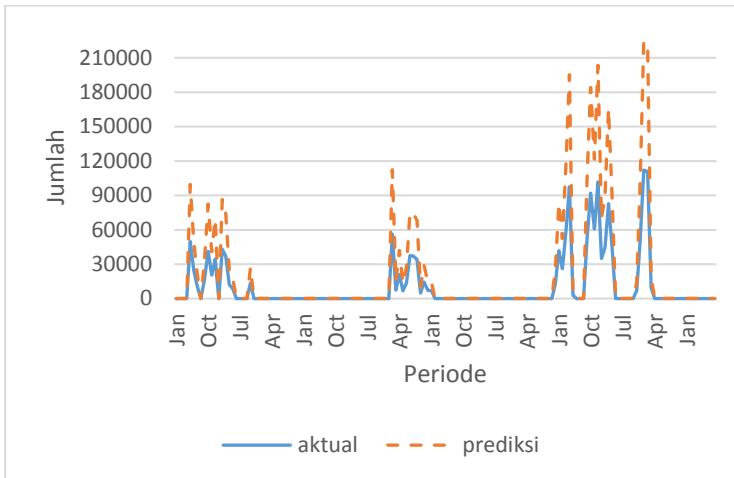
beras pada periode mendatang, dapat dilihat dalam LAMPIRAN. Gambar 6.7 menunjukkan dari periode Januari 2017 hingga Desember 2018 cenderung menurun. Hal ini menyatakan bahwa peramalan jumlah impor beras dari dan hingga periode tersebut berkurang dan menurun.



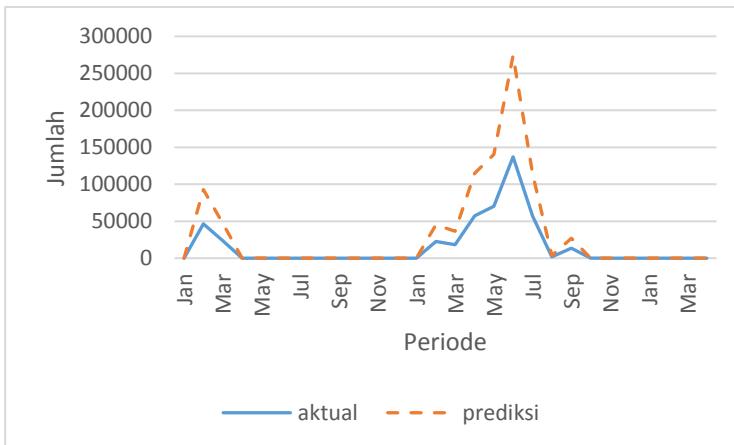
Gambar 6.7 Hasil Peramalan Periode Mendatang (Data Transformasi)

6.4 Analisis Perbandingan Hasil Peramalan Data Transformasi dan Dtransformasi

Dalam sub bab ini akan dilakukan tahap perbandingan hasil peramalan yang telah didetransformasi. Tujuannya adalah untuk mengembalikan nilai peramalan ke bentuk asli dengan mengubah nilai masing-masing peramalan sesuai dengan rumus. Gambar 6.8 merupakan grafik perbandingan nilai data *training* dari data transformasi yang sudah di detransformasikan dengan data aktual. Dan Gambar 6.9 merupakan grafik perbandingan nilai data *testing* dari data transformasi yang sudah di detransformasikan dengan data aktual.

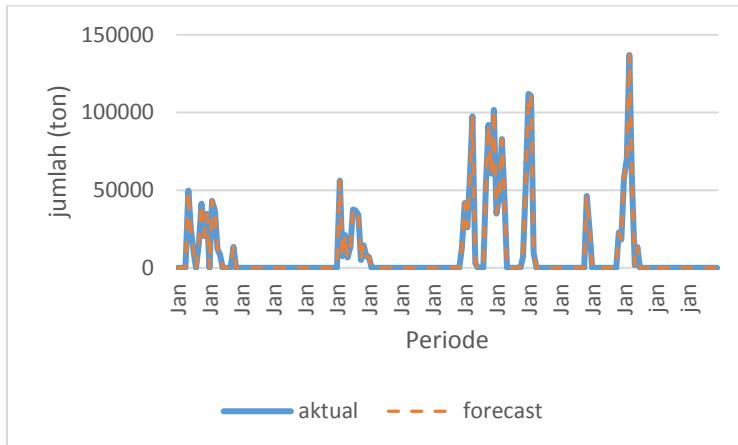


Gambar 6.8 Perbandingan Data Aktual dan Prediksi pada Data Training



Gambar 6.9 Perbandingan Data Aktual dan Prediksi pada Data Testing

Gambar 6.10 menunjukkan dari periode Januari 2017 hingga Desember 2018 cenderung menurun. Hal ini menyatakan bahwa peramalan jumlah impor beras dari dan hingga periode tersebut berkurang dan menurun.



Gambar 6.10 Grafik Hasil Peramalan

Tabel 6.4 menunjukkan hasil pengukuran kinerja model ANN dengan menggunakan nilai MAD, RMSE dan MDA. Nilai validasi tersebut untuk *training set* dan *testing set* pada data detransformasi yang dicantumkan dalam satu table dengan tujuan sebagai perbandingan.

Tabel 6.4 Perbandingan Hasil Peramalan

Data Set	MAD	RMSE	MDA
Training	1607575	314718	67.1%
Testing	448056	184288	70.3%

Pada Tabel 6.4 didapatkan bahwa MAD pada uji coba didapatkan $> 10\%$ dan nilai RMSE testing adalah $> 10\%$. Hal tersebut dapat dikatakan bahwa model yang dihasilkan ARIMA (1,0,0) dan ANN (13,7,1) memiliki kemampuan yang kurang baik dengan memiliki tingkat kenaikan dan turunnya data $<100\%$, yang dapat dikatakan bahwa peramalan yang dihasilkan kurang baik pula.

BAB VII

KESIMPULAN DAN SARAN

Pada bab ini menjelaskan tentang kesimpulan dari penelitian yang telah dilakukan dan saran yang dapat diberikan untuk pengembangan penelitian yang lebih baik.

7.1 Kesimpulan

Berdasarkan hasil dari uji coba pada tugas akhir ini, dapat ditarik kesimpulan bahwa:

Berdasarkan hasil dari uji coba menggunakan kedua metode tersebut pada tugas akhir ini, dapat ditarik kesimpulan sebagai berikut:

1. Model ARIMA-ANN dapat digunakan untuk meramalkan jumlah impor beras.
2. Model ARIMA terdiri dari AR dengan ordo 1 menunjukkan nilai lag 1, *differencing* dengan ordo 0, MA dengan ordo 0 sehingga model ARIMA tersebut adalah (1,0,0), pada uji coba model didapatkan nilai MDA sebesar 94% yang menunjukkan bahwa model tersebut layak untuk digunakan.
3. Model ARIMA ini dilanjutkan dengan menggunakan metode ANN dengan 1 input layer dengan 12 node, 1 hidden layer dengan 7 node, dan 1 output layer. Pada uji coba model didapatkan nilai MDA sebesar 61,5% yang artinya model ANN dapat digunakan untuk meramalkan jumlah impor beras pada periode selanjutnya.
4. Hasil peramalan jumlah impor beras menggunakan metode ARIMA-ANN memiliki nilai MDA 67,1% pada data training serta MDA 70,3% pada data testing yang menunjukkan bahwa model memiliki tingkat keakuratan yang cukup baik.

7.2 Saran

Berdasarkan hasil penelitian pada tugas akhir ini, saran yang dapat penulis berikan untuk penelitian lebih lanjut yaitu:

1. Parameter yang digunakan dalam proses ANN, *training cycles* menggunakan 100-500 *cycles*, hidden layer dengan lebih banyak node, momemntum dan *learning rate* menggunakan nilai 0,1-0,9. Untuk penelitian kedepan dapat menambahkan nilai *training cycles* dengan menggunakan nilai diatas 500.
2. Dalam penggeraan tugas akhir dengan menggunakan data yang sama dapat dilakukan dengan metode lain, seperti ARIMA-Regresi, SARIMA, ARIMAX dan metode *hybrid* lainnya.

DAFTAR PUSTAKA

- [1] IMF Emerging and Developing Economies List. World Economic Outlook Database, April 2010.
- [2] Mykamus English Malay, "Appakah maksud intermittent?", [Online]. Available : <http://mykamus.com/free/2010/09/intermittent/>
- [3] D. E. Rufiyanti, "IMPLEMENTASI JARINGAN SARAF TIRUAN BACKPROPAGATION DENGAN INPUT MODEL ARIMA UNTUK PERAMALAN HARGA SAHAM," Universitas Negeri Semarang, Semarang, 2015.
- [4] G. P. Zhang, Neural Networks for Classification: A Survey, IEEE Transactions On Systems, Man and Cybernetics, 2000.
- [5] X. Wang and M. Meng, A Hybrid Neural Network and ARIMA Model for Energy Consumption Forecasting, Journal Of Computer, 2012.
- [6] I. J. Econ, M. Sci, Y. M. Hadrat, E. N. I. K, and E. S. Eric, "International Journal of Economics & Inflation Forecasting in Ghana-Artificial Neural Network Model Approach," vol. 4, no. 8, pp. 8–13, 2015.
- [7] Islami, "PERAMALAN HARGA BERAS RIIL DAN PRODUKSI BERAS DI PROVINSI JAWA TIMUR, FORECASTING THE REAL PRICE OF RICE AND RICE PRODUCTION IN EAST JAVA," *Paper and Presentations of Statistics*, p. RSSt 658.816 Isl p, 2014.
- [8] Susanto Yudi, S.S.U Ulama, "Pemodelan Curah Hujan dengan Pendekatan Model ARIMA, Feed Forward Neural Network dan Hybrid (ARIMA-NN) di Banyuwangi," Jurnal Sains dan Seni ITS, vol.5, no. 2, 2016.
- [9] H. Himawan, "EFEKTIFITAS PENGGUNAAN METODE EXPONENTIAL SMOOTHING PADA PERAMALAN PRODUK," 2005.

- [10] S. Makridakis, Metode dan Aplikasi Peramalan, Jakarta: Erlangga, 1999.
- [11] D. R. Mahendra, "Forecasting Techniques," [Online]. Available:<http://nsdl.niscair.res.in/jspui/bitstream/123456789/829/1/CHAPTER6%20FORECASTING%20TECHNIQUES-%20Formatted.pdf>.
- [12] A. A. Surihardi, "Penerapan Metode Single Moving Average dan Exponential Smoothing Dalam Peramalan Permintaan Produk Meubel Jenis Coffee Table Pada Java Furniture Klaten," 2009.
- [13] P. A, Forecasting With Univariate Box – Jenkins Model, New Jersey (US): John Willey & Sons, Inc, 1983.
- [14] H. C, Neural Network and Their Statistical Application, SSRN Working Paper, 2006.
- [15] B. Fatkhurrozi and M. . A. Muslim, "Penggunaan Artificial Neuro Fuzzy Inference Sistem (ANFIS) dalam Penentuan Status Aktivitas Gunung Merapi," *Jurnal EEC CIS*, pp. vol. 6, no. 2, pp. 113–118, 2012.
- [16] Rajasekaran S.,GA. Vijayalakshmi Pai, "Neural Network, Fuzzy Logic and Genetic Algorithms", Prentice-Hall of India, New Delhi, 2005.
- [17] Kusrini, & Luthfi, E. T. , 2009, Algoritma Data mining. Yogyakarta: Andi.
- [18] Shukla, A., Tiwari, R., & Kala, R. ,2010, Real Life Application of Soft Computing. CRC Press.
- [19] Gorunescu, F. , 2011, Data Mining Concept Model Technique. India: Springer.
- [20] Larose, D. T. , 2005, Discovering Knowledge in Data. Canada: Wiley Interscience.
- [21] Astuti, E. D. , 2009, Pengantar Jaringan Saraf Tiruan. Wonosobo: Star Publishing.
- [22] Faruk DO. 2010. A hybrid neural network and ARIMA model for water quality time series prediction. Eng App Intelligence. 23:586-594.

- [23] Zhang G. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *J.Neurocomputing* 50:159-175.
- [24] Munarsih E. 2011. Penerapan Model ARIMANeural Network Hybrid untuk Peramalan Time Series. Thesis. S2 Matematika FMIPA Universitas Gadjah Mada. Yogyakarta.
- [25] D. W. Hanke, J. E. & Wichern, *Business Forecasting*, 8th ed. New Jersey: Prentice Hall, 2005.
- [26] Nurmahaludin, Perbandingan Algoritma Particle Swarm Optimization dan Regresi pada Peramalan Waktu Beban Puncak, *Jurnal POROS TEKNIK*, 2014.
- [27] J. J. Siang, "Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan MATLAB," Andi, Yogyakarta, 2005.
- [28] S. Kusumadewi, "Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB & EXCEL LINK," Graha Ilmu, Yogyakarta, 2004.
- [29] M. H. & S. H. O. Schnader, "Evaluating predictions of change," *Journal of Business*, pp. 99-107, 1990.
- [30] G. P. Zhang, "Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model," 2003. [Online]. Available: www.elsevier.com/locate/neucom. [Accessed 27 September 2017].

Halaman ini sengaja dikosongkan

BIODATA PENULIS



Penulis lahir di Lumajang, 04 Agustus 1996, dengan nama lengkap Rima Ika Agustin. Penulis merupakan anak pertama dari dua bersaudara.

Riwayat pendidikan penulis yaitu SD Negeri Pasirian 04, SMP Negeri 1 Pasirian , SMA Negeri 1 Tempeh, dan akhirnya menjadi salah satu mahasiswi Sistem Informasi ITS angkatan 2014 melalui jalur SNMPTN dengan NRP 5214100011.

Selama kuliah penulis bergabung dalam organisasi kemahasiswaan, yaitu Jamaah Masjid Manarul Ilmi selama 3 tahun kepengurusan, UKM KSR PMI ITS 2 tahun kepengurusan dan LDJ KISI ITS selama 2 tahun kepengurusan.

Penulis mengambil bidang minat Rekayasa Data dan Intelegensi Bisnis (RDIB) di Jurusan Sistem Informasi ITS. Penulis dapat dihubungi melalui *email* rimaikaagustin@gmail.com.

Halaman ini sengaja dikosongkan

LAMPIRAN A

Lampiran A berisi tentang Data Realisasi Penerimaan Beras Luar Negeri, Data Transformasi Awal dan Data Transformasi kedua yang menggunakan Minitab.

Tahun	Bulan	Jumlah(ton)	Transformasi Awal	Transformasi Minitab
2002	Jan	0	1.6021	0.246663
	Feb	0	1.60206	0.246663
	Mar	0	1.60206	0.246663
	Apr	0	1.60206	0.246663
	May	49700	4.696706	0.010111
	Jun	24794	4.395043	0.012314
	Jul	10600	4.026942	0.015967
	Aug	0	1.60206	0.246663
	Sep	15800	4.199755	0.014094
	Oct	41275	4.616108	0.010644
	Nov	20450	4.311542	0.013036
	Dec	34600	4.539578	0.011186
2003	Jan	0	1.60206	0.246663
	Feb	43243	4.636317	0.010507
	Mar	36900	4.567497	0.010984
	Apr	12021	4.081383	0.015343
	May	8500	3.931458	0.017147
	Jun	0	1.60206	0.246663
	Jul	0	1.60206	0.246663
	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663
	Oct	13500	4.131619	0.014795
	Nov	0	1.60206	0.246663
	Dec	0	1.60206	0.246663
2004	Jan	0	1.60206	0.246663
	Feb	0	1.60206	0.246663
	Mar	0	1.60206	0.246663
	Apr	0	1.60206	0.246663
	May	0	1.60206	0.246663
	Jun	0	1.60206	0.246663
	Jul	0	1.60206	0.246663
	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663

Tahun	Bulan	Jumlah(ton)	Transformasi Awal	Transformasi Minitab
2005	Oct	0	1.60206	0.246663
	Nov	0	1.60206	0.246663
	Dec	0	1.60206	0.246663
	Jan	0	1.60206	0.246663
	Feb	0	1.60206	0.246663
	Mar	0	1.60206	0.246663
	Apr	0	1.60206	0.246663
	May	0	1.60206	0.246663
	Jun	0	1.60206	0.246663
	Jul	0	1.60206	0.246663
	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663
2006	Oct	0	1.60206	0.246663
	Nov	0	1.60206	0.246663
	Dec	0	1.60206	0.246663
	Jan	0	1.60206	0.246663
	Feb	0	1.60206	0.246663
	Mar	0	1.60206	0.246663
	Apr	0	1.60206	0.246663
	May	0	1.60206	0.246663
	Jun	0	1.60206	0.246663
	Jul	0	1.60206	0.246663
	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663
2007	Oct	0	1.60206	0.246663
	Nov	0	1.60206	0.246663
	Dec	0	1.60206	0.246663
	Jan	0	1.60206	0.246663
	Feb	56100	4.749272	0.009782
	Mar	7450	3.874482	0.017906
	Apr	21000	4.323046	0.012933
	May	6700	3.82866	0.01855
	Jun	13489	4.131266	0.014799
	Jul	37650	4.576226	0.010922
	Aug	37000	4.568671	0.010975
	Sep	34100	4.533264	0.011232
2008	Oct	5000	3.702431	0.020492
	Nov	14400	4.159567	0.014502
	Dec	7200	3.859739	0.01811
	Jan	7175	3.858236	0.018131
	Feb	0	1.60206	0.246663

Tahun	Bulan	Jumlah(ton)	Transformasi Awal	Transformasi Minitab
2009	Mar	0	1.60206	0.246663
	Apr	0	1.60206	0.246663
	May	0	1.60206	0.246663
	Jun	0	1.60206	0.246663
	Jul	0	1.60206	0.246663
	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663
	Oct	0	1.60206	0.246663
	Nov	0	1.60206	0.246663
	Dec	0	1.60206	0.246663
	Jan	0	1.60206	0.246663
	Feb	0	1.60206	0.246663
2010	Mar	0	1.60206	0.246663
	Apr	0	1.60206	0.246663
	May	0	1.60206	0.246663
	Jun	0	1.60206	0.246663
	Jul	0	1.60206	0.246663
	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663
	Oct	0	1.60206	0.246663
	Nov	0	1.60206	0.246663
	Dec	0	1.60206	0.246663
	Jan	0	1.60206	0.246663
	Feb	0	1.60206	0.246663
2011	Mar	0	1.60206	0.246663
	Apr	0	1.60206	0.246663
	May	0	1.60206	0.246663
	Jun	0	1.60206	0.246663
	Jul	0	1.60206	0.246663
	Jan	41610	4.619614	0.01062
	Feb	26099	4.417294	0.012131
	Mar	58115	4.764586	0.009689

Tahun	Bulan	Jumlah(ton)	Transformasi Awal	Transformasi Minitab
2012	Aug	0	1.60206	0.246663
	Sep	52450	4.720075	0.009963
	Oct	92089	4.964397	0.008576
	Nov	60738	4.783743	0.009574
	Dec	101599	5.00706	0.008361
	Jan	34934	4.543748	0.011155
	Feb	44502	4.648769	0.010423
	Mar	82830	4.918398	0.008816
	Apr	45010	4.653693	0.010391
	May	100	2.146438	0.103466
	Jun	0	1.60206	0.246663
	Jul	0	1.60206	0.246663
2013	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663
	Oct	0	1.60206	0.246663
	Nov	6981	3.846389	0.018298
	Dec	51356	4.710926	0.01002
	Jan	112036	5.049513	0.008154
	Feb	110716	5.044367	0.008178
	Mar	9677	3.987532	0.01644
	Apr	0	1.60206	0.246663
	May	0	1.60206	0.246663
	Jun	0	1.60206	0.246663
2014	Jul	0	1.60206	0.246663
	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663
	Oct	0	1.60206	0.246663
	Nov	0	1.60206	0.246663
	Dec	0	1.60206	0.246663
	Jan	0	1.60206	0.246663
	Feb	0	1.60206	0.246663
	Mar	0	1.60206	0.246663
	Apr	0	1.60206	0.246663
	May	0	1.60206	0.246663
	Jun	0	1.60206	0.246663

Tahun	Bulan	Jumlah(ton)	Transformasi Awal	Transformasi Minitab
2015	Jan	0	1.60206	0.246663
	Feb	0	1.60206	0.246663
	Mar	0	1.60206	0.246663
	Apr	0	1.60206	0.246663
	May	0	1.60206	0.246663
	Jun	0	1.60206	0.246663
	Jul	0	1.60206	0.246663
	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663
	Oct	0	1.60206	0.246663
	Nov	22654	4.355916	0.012645
	Dec	18269	4.262667	0.013485
2016	Jan	57288	4.758365	0.009726
	Feb	70093	4.84592	0.009214
	Mar	137047	5.136996	0.007748
	Apr	56919	4.755561	0.009743
	May	1750	3.252747	0.030103
	Jun	13541	4.132937	0.014781
	Jul	40	1.900367	0.148543
	Aug	0	1.60206	0.246663
	Sep	0	1.60206	0.246663
	Oct	0	1.60206	0.246663
	Nov	0	1.60206	0.246663
	Dec	0	1.60206	0.246663

Halaman ini sengaja dikosongkan

LAMPIRAN B

Lampiran B berisi tentang hasil uji signifikansi pada model ARIMA menggunakan data training dan data peramalan serta data residu menggunakan model ARIMA.

1. Uji Signifikansi Model ARIMA

a. Model ARIMA (0,0,1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.793922	0.057631	13.77600	0.0000
SIGMASQ	0.017665	0.003706	4.767216	0.0000
R-squared	-0.597361	Mean dependent var	0.180020	
Adjusted R-squared	-0.607940	S.D. dependent var	0.105507	
S.E. of regression	0.133787	Akaike info criterion	-1.165641	
Sum squared resid	2.702755	Schwarz criterion	-1.126028	
Log likelihood	91.17157	Hannan-Quinn criter.	-1.149550	
Durbin-Watson stat	0.934174			
Inverted MA Roots	.79			

b. Model ARIMA (0,0,2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(2)	0.757481	0.062974	12.02848	0.0000
SIGMASQ	0.019436	0.003942	4.930926	0.0000
R-squared	-0.757526	Mean dependent var	0.180020	
Adjusted R-squared	-0.769166	S.D. dependent var	0.105507	
S.E. of regression	0.140334	Akaike info criterion	-1.065443	
Sum squared resid	2.973757	Schwarz criterion	-1.025830	
Log likelihood	83.50641	Hannan-Quinn criter.	-1.049352	
Durbin-Watson stat	0.552356			
Inverted MA Roots	.-00+.87i	-.00-.87i		

c. Model ARIMA (0,0,3)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(3)	0.681804	0.067584	10.08828	0.0000
SIGMASQ	0.022713	0.004531	5.012417	0.0000
R-squared	-1.053862	Mean dependent var	0.180020	
Adjusted R-squared	-1.067463	S.D. dependent var	0.105507	
S.E. of regression	0.151705	Akaike info criterion	-0.908517	
Sum squared resid	3.475160	Schwarz criterion	-0.868904	
Log likelihood	71.50157	Hannan-Quinn criter.	-0.892426	
Durbin-Watson stat	0.460795			
Inverted MA Roots	.44+.76i	.44-.76i	-.88	

d. Model ARIMA (0,0,4)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(4)	0.6111748	0.084237	7.262246	0.0000
SIGMASQ	0.024751	0.005182	4.775979	0.0000
R-squared	-1.238135	Mean dependent var	0.180020	
Adjusted R-squared	-1.252957	S.D. dependent var	0.105507	
S.E. of regression	0.158364	Akaike info criterion	-0.822600	
Sum squared resid	3.786953	Schwarz criterion	-0.782986	
Log likelihood	64.92887	Hannan-Quinn criter.	-0.806508	
Durbin-Watson stat	0.407200			
Inverted MA Roots	.63-.63i	.63+.63i	-.63+.63i	-.63-.63i

e. Model ARIMA (0,0,5)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(5)	0.570092	0.078500	7.262272	0.0000
SIGMASQ	0.026128	0.005508	4.743761	0.0000
R-squared	-1.362646	Mean dependent var	0.180020	
Adjusted R-squared	-1.378293	S.D. dependent var	0.105507	
S.E. of regression	0.162709	Akaike info criterion	-0.767871	
Sum squared resid	3.997627	Schwarz criterion	-0.720258	
Log likelihood	60.74216	Hannan-Quinn criter.	-0.751780	
Durbin-Watson stat	0.277733			
Inverted MA Roots	.72-.53i -.89	.72+.53i	-.28+.85i	-.28-.85i

f. Model ARIMA (0,0,6)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(6)	0.497784	0.084077	5.920547	0.0000
SIGMASQ	0.028080	0.006173	4.549075	0.0000
R-squared	-1.539119	Mean dependent var	0.180020	
Adjusted R-squared	-1.555934	S.D. dependent var	0.105507	
S.E. of regression	0.168877	Akaike info criterion	-0.697515	
Sum squared resid	4.296221	Schwarz criterion	-0.657901	
Log likelihood	55.35990	Hannan-Quinn criter.	-0.681423	
Durbin-Watson stat	0.302579			
Inverted MA Roots	.77+.45i -.77+.45i	.77-.45i -.77-.45i	.00-.89i .00+.89i	

g. Model ARIMA (1,0,0)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.938734	0.043441	21.60958	0.0000
SIGMASQ	0.005345	0.000397	13.45087	0.0000
R-squared	0.516649	Mean dependent var	0.180020	
Adjusted R-squared	0.513448	S.D. dependent var	0.105507	
S.E. of regression	0.073594	Akaike info criterion	-2.353586	
Sum squared resid	0.817836	Schwarz criterion	-2.313973	
Log likelihood	182.0494	Hannan-Quinn criter.	-2.337495	
Durbin-Watson stat	2.257479			
Inverted AR Roots	.94			

h. Model ARIMA (1,0,1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.958055	0.037627	25.46171	0.0000
MA(1)	-0.160577	0.059827	-2.306251	0.0225
SIGMASQ	0.005233	0.000388	13.47949	0.0000
R-squared	0.526837	Mean dependent var	0.180020	
Adjusted R-squared	0.520529	S.D. dependent var	0.105507	
S.E. of regression	0.073057	Akaike info criterion	-2.361419	
Sum squared resid	0.800597	Schwarz criterion	-2.301999	
Log likelihood	183.6486	Hannan-Quinn criter.	-2.337282	
Durbin-Watson stat	1.985358			
Inverted AR Roots	.96			
Inverted MA Roots	.16			

i. Model ARIMA (1,0,2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.933749	0.055937	16.69300	0.0000
MA(2)	0.042114	0.417912	0.100774	0.9199
SIGMASQ	0.005339	0.000432	12.35795	0.0000
R-squared	0.517261	Mean dependent var	0.180020	
Adjusted R-squared	0.510824	S.D. dependent var	0.105507	
S.E. of regression	0.073793	Akaike info criterion	-2.341781	
Sum squared resid	0.816801	Schwarz criterion	-2.282360	
Log likelihood	182.1462	Hannan-Quinn criter.	-2.317643	
Durbin-Watson stat	2.227715			
Inverted AR Roots	.93			
Inverted MA Roots	-.00+.21i	-.00-.21i		

j. Model ARIMA (1,0,3)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.957934	0.036251	26.42532	0.0000
MA(3)	-0.173355	0.084126	-2.060672	0.0411
SIGMASQ	0.005252	0.000414	12.69466	0.0000
R-squared	0.525048	Mean dependent var	0.180020	
Adjusted R-squared	0.518715	S.D. dependent var	0.105507	
S.E. of regression	0.073195	Akaike info criterion	-2.357212	
Sum squared resid	0.803625	Schwarz criterion	-2.297792	
Log likelihood	183.3267	Hannan-Quinn criter.	-2.333075	
Durbin-Watson stat	2.336286			
Inverted AR Roots	.96			
Inverted MA Roots	.56	-.28-.48i	-.28+.48i	

k. Model ARIMA (1,0,4)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.952574	0.037618	25.32201	0.0000
MA(4)	-0.131901	0.055095	-2.394059	0.0179
SIGMASQ	0.005270	0.000400	13.18453	0.0000
R-squared	0.523495	Mean dependent var	0.180020	
Adjusted R-squared	0.517142	S.D. dependent var	0.105507	
S.E. of regression	0.073314	Akaike info criterion	-2.354196	
Sum squared resid	0.806252	Schwarz criterion	-2.294775	
Log likelihood	183.0960	Hannan-Quinn criter.	-2.330058	
Durbin-Watson stat	2.282913			
Inverted AR Roots	.95			
Inverted MA Roots	.60	.00-.60i	-.00+.60i	-.60

1. Model ARIMA (1,0,5)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.926287	0.048331	19.16556	0.0000
MA(5)	0.141615	0.046654	3.035429	0.0028
SIGMASQ	0.005213	0.000404	12.90431	0.0000
R-squared	0.528601	Mean dependent var	0.180020	
Adjusted R-squared	0.522316	S.D. dependent var	0.105507	
S.E. of regression	0.072921	Akaike info criterion	-2.364851	
Sum squared resid	0.797613	Schwarz criterion	-2.305431	
Log likelihood	183.9111	Hannan-Quinn criter.	-2.340714	
Durbin-Watson stat	2.176138			
Inverted AR Roots	.93			
Inverted MA Roots	.55-.40i .88	.55+.40i -.74	-.21+.64i .37+.64i	-.21-.64i

m. Model ARIMA (1,0,6)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.955123	0.036657	26.05594	0.0000
MA(6)	-0.157940	0.078481	-2.012462	0.0460
SIGMASQ	0.005236	0.000381	13.75235	0.0000
R-squared	0.526529	Mean dependent var	0.180020	
Adjusted R-squared	0.502016	S.D. dependent var	0.105507	
S.E. of regression	0.073081	Akaike info criterion	-2.359866	
Sum squared resid	0.801119	Schwarz criterion	-2.300446	
Log likelihood	183.5297	Hannan-Quinn criter.	-2.335728	
Durbin-Watson stat	2.243024			
Inverted AR Roots	.96			
Inverted MA Roots	.74 -.37-.64i	.37-.64i -.74	.37+.64i -.37+.64i	

n. Model ARIMA (2,0,0)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.897820	0.054938	16.34234	0.0000
SIGMASQ	0.008759	0.000852	10.28114	0.0000
R-squared	0.207954	Mean dependent var	0.180020	
Adjusted R-squared	0.202709	S.D. dependent var	0.105507	
S.E. of regression	0.094208	Akaike info criterion	-1.852192	
Sum squared resid	1.340152	Schwarz criterion	-1.812579	
Log likelihood	143.6927	Hannan-Quinn criter.	-1.836101	
Durbin-Watson stat	1.133133			
Inverted AR Roots	.95	-.95		

o. Model ARIMA (2,0,1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.882143	0.083593	10.55287	0.0000
MA(1)	0.947942	0.047439	19.98251	0.0000
SIGMASQ	0.005342	0.000398	13.43805	0.0000
R-squared	0.516940	Mean dependent var	0.180020	
Adjusted R-squared	0.510499	S.D. dependent var	0.105507	
S.E. of regression	0.073817	Akaike info criterion	-2.340967	
Sum squared resid	0.817344	Schwarz criterion	-2.281546	
Log likelihood	182.0840	Hannan-Quinn criter.	-2.316829	
Durbin-Watson stat	2.272839			
Inverted AR Roots	.94	-.94		
Inverted MA Roots	-.95			

p. Model ARIMA (2,0,2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.946303	0.041644	22.72386	0.0000
MA(2)	-0.263740	0.093383	-2.824282	0.0054
SIGMASQ	0.008488	0.000889	9.548802	0.0000
R-squared	0.232496	Mean dependent var	0.180020	
Adjusted R-squared	0.222263	S.D. dependent var	0.105507	
S.E. of regression	0.093046	Akaike info criterion	-1.869080	
Sum squared resid	1.298626	Schwarz criterion	-1.809660	
Log likelihood	145.9846	Hannan-Quinn criter.	-1.844942	
Durbin-Watson stat	1.006093			
Inverted AR Roots	.97		-.97	
Inverted MA Roots	.51		-.51	

q. Model ARIMA (2,0,3)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.948465	0.036772	25.79283	0.0000
MA(3)	-0.284610	0.072113	-3.946713	0.0001
SIGMASQ	0.008265	0.000789	10.47830	0.0000
R-squared	0.252644	Mean dependent var	0.180020	
Adjusted R-squared	0.242679	S.D. dependent var	0.105507	
S.E. of regression	0.091816	Akaike info criterion	-1.887874	
Sum squared resid	1.264536	Schwarz criterion	-1.828454	
Log likelihood	147.4224	Hannan-Quinn criter.	-1.863737	
Durbin-Watson stat	1.257821			
Inverted AR Roots	.97		-.97	
Inverted MA Roots	.66		-.33+.57i	-.33-.57i

r. Model ARIMA (2,0,4)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.925636	0.045300	20.43326	0.0000
MA(4)	-0.157839	0.078155	-2.019573	0.0452
SIGMASQ	0.008617	0.000848	10.16406	0.0000
R-squared	0.220772	Mean dependent var	0.180020	
Adjusted R-squared	0.210383	S.D. dependent var	0.105507	
S.E. of regression	0.093754	Akaike info criterion	-1.854612	
Sum squared resid	1.318463	Schwarz criterion	-1.795192	
Log likelihood	144.8778	Hannan-Quinn criter.	-1.830475	
Durbin-Watson stat	1.185733			
Inverted AR Roots	.96		-.96	
Inverted MA Roots	.63		-.00+.63i	-.00-.63i

s. Model ARIMA (2,0,5)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.889450	0.057477	15.47499	0.0000
MA(5)	0.050811	0.056788	0.894745	0.3724
SIGMASQ	0.008740	0.000858	10.18397	0.0000
R-squared	0.209703	Mean dependent var	0.180020	
Adjusted R-squared	0.199166	S.D. dependent var	0.105507	
S.E. of regression	0.094416	Akaike info criterion	-1.842236	
Sum squared resid	1.337193	Schwarz criterion	-1.782816	
Log likelihood	143.9311	Hannan-Quinn criter.	-1.810899	
Durbin-Watson stat	1.104811			
Inverted AR Roots	.94		-.94	
Inverted MA Roots	.45-.32i		.45+.32i	-.17+.52i
	-.55			

t. Model ARIMA (2,0,6)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.907900	0.052907	17.16035	0.0000
MA(6)	-0.055982	0.070096	-0.798718	0.4257
SIGMASQ	0.008735	0.000832	10.50386	0.0000
R-squared	0.210146	Mean dependent var	0.180020	
Adjusted R-squared	0.199615	S.D. dependent var	0.105507	
S.E. of regression	0.094391	Akaike info criterion	-1.841600	
Sum squared resid	1.336442	Schwarz criterion	-1.782179	
Log likelihood	143.8824	Hannan-Quinn criter.	-1.817462	
Durbin-Watson stat	1.141347			
Inverted AR Roots	.95	.95		
Inverted MA Roots	.62	.31+.54i	.31-.54i	-.31-.54i
		-.31+.54i	.62	

2. Hasil Peramalan Menggunakan Data Training pada Eviews

Tahun	Bulan	Forecast	Residu
2002	Jan		
	Feb	0.23155084	0.015112
	Mar	0.23155084	0.015112
	Apr	0.23155084	0.015112
	May	0.23155084	-0.22144
	Jun	0.00949109	0.002823
	Jul	0.01155957	0.004407
	Aug	0.01498876	0.231674
	Sep	0.23155084	-0.21746
	Oct	0.01323022	-0.00259
	Nov	0.00999178	0.003044
	Dec	0.01223724	-0.00105
2003	Jan	0.01050041	0.236163
	Feb	0.23155084	-0.22104
	Mar	0.00986298	0.001121
	Apr	0.01031093	0.005032
	May	0.01440272	0.002744
	Jun	0.016096	0.230567
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	0.015112
	Oct	0.23155084	-0.21676
	Nov	0.01388882	0.232774
	Dec	0.23155084	0.015112
2004	Jan	0.23155084	0.015112
	Feb	0.23155084	0.015112
	Mar	0.23155084	0.015112

Tahun	Bulan	Forecast	Residu
2005	Apr	0.23155084	0.015112
	May	0.23155084	0.015112
	Jun	0.23155084	0.015112
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	0.015112
	Oct	0.23155084	0.015112
	Nov	0.23155084	0.015112
	Dec	0.23155084	0.015112
	Jan	0.23155084	0.015112
	Feb	0.23155084	0.015112
	Mar	0.23155084	0.015112
2006	Apr	0.23155084	0.015112
	May	0.23155084	0.015112
	Jun	0.23155084	0.015112
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	0.015112
	Oct	0.23155084	0.015112
	Nov	0.23155084	0.015112
	Dec	0.23155084	0.015112
	Jan	0.23155084	0.015112
	Feb	0.23155084	0.015112
	Mar	0.23155084	0.015112
2007	Apr	0.23155084	0.015112
	May	0.23155084	0.015112
	Jun	0.23155084	0.015112
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	0.015112
	Oct	0.23155084	0.015112
	Nov	0.23155084	0.015112
	Dec	0.23155084	0.015112
	Jan	0.01214078	0.00641
	Feb	0.01741379	-0.00261
	Mar	0.01389234	-0.00297
	Apr	0.01025263	0.000723
	May	0.01030306	0.000929
	Jun		
	Jul		
	Aug		
	Sep		

Tahun	Bulan	Forecast	Residu
	Oct	0.01054391	0.009949
	Nov	0.01923695	-0.00473
	Dec	0.01361349	0.004497
2008	Jan	0.01700065	0.00113
	Feb	0.01702031	0.229643
	Mar	0.23155084	0.015112
	Apr	0.23155084	0.015112
	May	0.23155084	0.015112
	Jun	0.23155084	0.015112
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	0.015112
	Oct	0.23155084	0.015112
	Nov	0.23155084	0.015112
	Dec	0.23155084	0.015112
2009	Jan	0.23155084	0.015112
	Feb	0.23155084	0.015112
	Mar	0.23155084	0.015112
	Apr	0.23155084	0.015112
	May	0.23155084	0.015112
	Jun	0.23155084	0.015112
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	0.015112
	Oct	0.23155084	0.015112
	Nov	0.23155084	0.015112
	Dec	0.23155084	0.015112
2010	Jan	0.23155084	0.015112
	Feb	0.23155084	0.015112
	Mar	0.23155084	0.015112
	Apr	0.23155084	0.015112
	May	0.23155084	0.015112
	Jun	0.23155084	0.015112
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	0.015112
	Oct	0.23155084	0.015112
	Nov	0.23155084	0.015112
	Dec	0.23155084	-0.21656
2011	Jan	0.01407189	-0.00345
	Feb	0.00996927	0.002161
	Mar	0.0113875	-0.0017

Tahun	Bulan	Forecast	Residu
2012	Apr	0.0090951	-0.00065
	May	0.00793129	0.01665
	Jun	0.02307507	0.223588
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	-0.22159
	Oct	0.00935221	-0.00078
	Nov	0.00805043	0.001523
	Dec	0.00898735	-0.00063
	Jan	0.0078484	0.003307
	Feb	0.01047182	-4.85E-05
	Mar	0.00978473	-0.00097
2013	Apr	0.00827611	0.002114
	May	0.009754	0.093712
	Jun	0.09712673	0.149536
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	0.015112
	Oct	0.23155084	0.015112
	Nov	0.23155084	-0.21325
	Dec	0.01717649	-0.00716
	Jan	0.00940625	-0.00125
	Feb	0.00765405	0.000524
	Mar	0.00767726	0.008763
2014	Apr	0.01543302	0.23123
	May	0.23155084	0.015112
	Jun	0.23155084	0.015112
	Jul	0.23155084	0.015112
	Aug	0.23155084	0.015112
	Sep	0.23155084	0.015112
	Oct	0.23155084	0.015112
	Nov	0.23155084	0.015112
	Dec	0.23155084	0.015112
	Jan	0.23155084	0.015112
	Feb	0.23155084	0.015112
	Mar	0.23155084	0.015112

3. Hasil Peramalan Menggunakan Data Testing pada Eviews

Tahun	Bulan	Forecast	Residu
2014	Oct		
	Nov	0.225353	-0.21504
	Dec	0.009422	0.003105
2015	Jan	0.011445	0.235218
	Feb	0.225353	0.02131
	Mar	0.225353	0.02131
	Apr	0.225353	0.02131
	May	0.225353	0.02131
	Jun	0.225353	0.02131
	Jul	0.225353	0.02131
	Aug	0.225353	0.02131
	Sep	0.225353	0.02131
	Oct	0.225353	0.02131
	Nov	0.225353	-0.21271
	Dec	0.011553	0.001932
2016	Jan	0.01232	-0.00259
	Feb	0.008886	0.000328
	Mar	0.008418	-0.00067
	Apr	0.007079	0.002665
	May	0.008902	0.021202
	Jun	0.027503	-0.01272
	Jul	0.013504	0.135039
	Aug	0.13571	0.110953
	Sep	0.225353	0.02131
	Oct	0.225353	0.02131
	Nov	0.225353	0.02131
	Dec	0.225353	0.02131

4. Peramalan periode mendatang menggunakan ARIMA

Tahun	Bulan	Forecast	Residu
2017	Jan	0.228485	-0.00321
	Feb	0.208745	-0.0027
	Mar	0.190923	-0.00228
	Apr	0.1748	-0.00209
	May	0.160039	-0.00163
	Jun	0.146785	-0.00138
	Jul	0.134736	-0.00116
	Aug	0.12377	-0.00098
	Sep	0.113777	-0.00083
	Oct	0.10466	-0.0007
	Nov	0.096334	-0.00058
	Dec	0.088723	-0.00049
2018	Jan	0.08176	-0.00041
	Feb	0.075385	-0.00034
	Mar	0.069542	-0.00028
	Apr	0.064183	-0.00022
	May	0.059266	-0.00018
	Jun	0.054749	-0.00014
	Jul	0.050599	-0.00011
	Aug	0.046783	-8.39E-05
	Sep	0.043272	-6.10E-05
	Oct	0.04004	-4.16E-05
	Nov	0.037063	-2.52E-05
	Dec	0.03432	-1.15E-05

Halaman ini sengaja dikosongkan

LAMPIRAN C

Lampiran C berisi data hasil trial dan error untuk menemukan parameter terbaik pada model ANN.

EPOCH = 500					
LEARNING RATE	MOMEN TUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.1	0.1	0.07086	0.5342	0.1951	0.28
0.2	0.1	0.07225	0.5634	0.2313	0.3078
0.3	0.1	0.06936	0.6417	0.2187	0.2902
0.4	0.1	0.06917	0.6308	0.2067	0.2718
0.5	0.1	0.09044	0.5206	0.3962	0.4426
0.6	0.1	0.11738	0.3582	0.2045	0.299
0.7	0.1	0.12516	0.3559	0.392	0.4328
0.8	0.1	0.14318	0.3004	0.3861	0.4295
0.9	0.1	0.15997	0.1453	0.2804	0.3569
0.1	0.2	0.71015	0.5404	0.1968	0.2802
0.2	0.2	0.0739	0.5565	0.2416	0.3174
0.3	0.2	0.0678	0.657	0.2152	0.2834
0.4	0.2	0.74245	0.6329	0.2753	0.3304
0.5	0.2	0.09397	0.5857	0.3058	0.3704
0.6	0.2	0.11432	0.5857	0.3058	0.3704
0.7	0.2	0.13293	0.3173	0.4469	0.4826
0.8	0.2	0.15141	0.2397	0.4519	0.4898
0.9	0.2	0.1682	0.129	0.4122	0.4609
0.1	0.3	0.07115	0.5481	0.1984	0.2803
0.2	0.3	0.07462	0.5758	0.2513	0.3233
0.3	0.3	0.06877	0.6621	0.2365	0.2978
0.4	0.3	0.07481	0.4138	0.4716	0.5683
0.5	0.3	0.11377	0.4014	0.2514	0.3303
0.6	0.3	0.12004	0.373	0.2538	0.325
0.7	0.3	0.13622	0.2324	0.4873	0.5211
0.8	0.3	0.15064	0.1682	0.4915	0.5318
0.9	0.3	0.1886	0.1316	0.4708	0.5114
0.1	0.4	0.07101	0.5553	0.1983	0.2799
0.2	0.4	0.07324	0.6297	0.2417	0.3113
0.3	0.4	0.07378	0.6217	0.2107	0.2911
0.4	0.4	0.08241	0.5759	0.3992	0.4406
0.5	0.4	0.13928	0.1865	0.5191	0.6191

EPOCH = 500					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.6	0.4	0.12985	0.2421	0.5105	0.5407
0.7	0.4	0.13959	0.2049	0.5579	0.5895
0.8	0.4	0.16813	0.0504	0.5841	0.6205
0.9	0.4	0.18104	0.015	0.5414	0.5788
0.1	0.5	0.07147	0.5624	0.1951	0.279
0.2	0.5	0.07799	0.5761	0.294	0.3572
0.3	0.5	0.10079	0.4638	0.3271	0.4079
0.4	0.5	0.08219	0.5317	0.4471	0.4881
0.5	0.5	0.1334	0.2789	0.4929	0.5224
0.6	0.5	0.13752	0.2006	0.5578	0.5873
0.7	0.5	0.17064	0.118	0.6088	0.6436
0.8	0.5	0.17384	0.0327	0.6405	0.6774
0.9	0.5	0.18718	0.0012	0.6282	0.6639
0.1	0.6	0.07332	0.5696	0.1909	0.2765
0.2	0.6	0.08014	0.5914	0.3155	0.369
0.3	0.6	0.11936	0.4138	0.4716	0.5683
0.4	0.6	0.12897	0.3621	0.5361	0.5827
0.5	0.6	0.15562	0.1404	0.232	0.3398
0.6	0.6	0.14958	0.2645	0.603	0.6294
0.7	0.6	0.18182	0.0574	0.6401	0.6759
0.8	0.6	0.20057	0.0244	0.6886	0.722
0.9	0.6	0.21359	0.0169	0.7409	0.7752
0.1	0.7	0.07483	0.5781	0.1848	0.2701
0.2	0.7	0.1063	0.458	0.3217	0.4081
0.3	0.7	0.14519	0.3405	0.2876	0.3654
0.4	0.7	0.15307	0.2283	0.21	0.3444
0.5	0.7	0.20882	0.5371	0.4471	0.4483
0.6	0.7	0.18974	0.3163	0.6511	0.6793
0.7	0.7	0.21535	0.2654	0.603	0.6294
0.8	0.7	0.24582	0.019	0.6922	0.7254
0.9	0.7	0.26087	0.0396	0.8479	0.8863
0.1	0.8	0.08436	0.5903	0.1533	0.2506
0.2	0.8	0.16251	0.4481	0.5228	0.5843
0.3	0.8	0.15521	0.3733	0.6473	0.6892
0.4	0.8	0.26061	0.0897	0.6912	0.7244
0.5	0.8	0.2981	-0.0704	1.02	1.063
0.6	0.8	0.30156	0.0344	0.7475	0.7819
0.7	0.8	0.31404	0.1039	0.4711	0.5121
0.8	0.8	0.33617	0.0375	0.5439	0.5794

EPOCH = 500					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.9	0.8	0.36609	0.0605	0.8656	0.9049
0.1	0.9	0.09369	0.7083	0.1437	0.2302
0.2	0.9	0.18131	0.5903	0.1533	0.2506
0.3	0.9	0.25471	-0.2195	0.1602	0.3092
0.4	0.9	0.48222	0.1203	0.6123	0.6456
0.5	0.9	0.6665	-0.0262	1.7688	1.795
0.6	0.9	0.5213	-0.0084	1.0942	1.1362
0.7	0.9	0.59869	0.0082	0.1324	0.3078
0.8	0.9	0.55975	0	0.1381	0.3061
0.9	0.9	0.72487	0	0.6158	0.649

EPOCH = 400					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.1	0.1	0.072189	0.5188	0.1961	0.2817
0.2	0.1	0.074427	0.5374	0.2359	0.3133
0.3	0.1	0.076849	0.565	0.2402	0.3189
0.4	0.1	0.075449	0.5796	0.221	0.2945
0.5	0.1	0.091766	0.5279	0.2184	0.3125
0.6	0.1	0.118776	0.341	0.2091	0.3029
0.7	0.1	0.1264	0.3393	0.3924	0.4341
0.8	0.1	0.142902	0.2742	0.3934	0.4372
0.9	0.1	0.161824	0.1329	0.2915	0.3638
0.1	0.2	0.072362	0.5249	0.1967	0.2813
0.2	0.2	0.075928	0.5383	0.2462	0.3215
0.3	0.2	0.074308	0.5994	0.2419	0.3136
0.4	0.2	0.082981	0.5545	0.2521	0.3217
0.5	0.2	0.094254	0.4743	0.1995	0.3145
0.6	0.2	0.112932	0.3933	0.235	0.3125
0.7	0.2	0.133584	0.3025	0.4534	0.4896
0.8	0.2	0.150473	0.2341	0.4441	0.4845
0.9	0.2	0.163063	0.1574	0.3757	0.4305
0.1	0.3	0.072687	0.5312	0.1973	0.2809
0.2	0.3	0.077646	0.538	0.2594	0.3329
0.3	0.3	0.074705	0.6141	0.2639	0.3289
0.4	0.3	0.079803	0.5891	0.3011	0.3596
0.5	0.3	0.117272	0.4002	0.2211	0.3046
0.6	0.3	0.124538	0.3528	0.2675	0.3343

EPOCH = 400					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.7	0.3	0.141016	0.2491	0.5009	0.5352
0.8	0.3	0.158929	0.21	0.5125	0.5496
0.9	0.3	0.164392	0.0428	0.506	0.5464
0.1	0.4	0.073132	0.5382	0.1985	0.2808
0.2	0.4	0.07822	0.5741	0.2559	0.3295
0.3	0.4	0.086764	0.581	0.255	0.3291
0.4	0.4	0.083971	0.5253	0.424	0.4685
0.5	0.4	0.127206	0.2084	0.3167	0.4453
0.6	0.4	0.132859	0.2084	0.3167	0.4453
0.7	0.4	0.148685	0.1424	0.565	0.5993
0.8	0.4	0.157327	0.0366	0.6041	0.6419
0.9	0.4	0.181249	0.0524	0.5516	0.5873
0.1	0.5	0.074059	0.5438	0.1965	0.2789
0.2	0.5	0.08319	0.5273	0.3084	0.3753
0.3	0.5	0.104412	0.4311	0.3803	0.458
0.4	0.5	0.101885	0.3684	0.5447	0.6309
0.5	0.5	0.139691	0.2032	0.498	0.5291
0.6	0.5	0.137273	0.2382	0.5517	0.5799
0.7	0.5	0.170998	0.1347	0.614	0.6488
0.8	0.5	0.184352	0.0537	0.6387	0.6722
0.9	0.5	0.186691	0.0202	0.6353	0.672
0.1	0.6	0.075749	0.5549	0.1893	0.2741
0.2	0.6	0.087678	0.5585	0.1802	0.2696
0.3	0.6	0.117776	0.378	0.5472	0.6329
0.4	0.6	0.141314	0.3321	0.4863	0.543
0.5	0.6	0.167282	0.1268	0.2209	0.3482
0.6	0.6	0.15387	0.3319	0.609	0.6405
0.7	0.6	0.181688	0.0514	0.6553	0.6918
0.8	0.6	0.196556	0.0295	0.7023	0.7406
0.9	0.6	0.213602	0.0306	0.741	0.7752
0.1	0.7	0.078146	0.5585	0.1802	0.2696
0.2	0.7	0.112912	0.4337	0.3602	0.4572
0.3	0.7	0.143557	0.3399	0.2847	0.3628
0.4	0.7	0.156465	0.2245	0.2164	0.3467
0.5	0.7	0.20635	0.2134	0.747	0.7802
0.6	0.7	0.196458	0.0679	0.6422	0.6788
0.7	0.7	0.214032	0.053	0.6257	0.6627
0.8	0.7	0.245817	0.0206	0.6922	0.7254
0.9	0.7	0.263376	0.5249	0.1967	0.2813

EPOCH = 400					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.1	0.8	0.091303	0.5108	0.1673	0.2685
0.2	0.8	0.175868	0.3189	0.7679	0.8845
0.3	0.8	0.190682	0.2952	0.5858	0.6344
0.4	0.8	0.260934	0.911	0.691	0.7242
0.5	0.8	0.29812	-0.0374	1.0201	1.063
0.6	0.8	0.301529	0.07	0.7475	0.7819
0.7	0.8	0.314027	0.0598	0.4712	0.5122
0.8	0.8	0.336172	0.0381	0.5439	0.5794
0.9	0.8	0.366088	0.0604	0.8656	0.9049
0.1	0.9	0.107936	0.6153	0.1771	0.2549
0.2	0.9	0.196741	0.2251	0.5158	0.5521
0.3	0.9	0.254245	0.2789	0.1604	0.3092
0.4	0.9	0.48222	0.1141	0.6124	0.6465
0.5	0.9	0.666504	-0.0269	1.7688	1.795
0.6	0.9	0.521299	-0.0085	1.0942	1.1362
0.7	0.9	0.598693	0.0082	0.1324	0.3078
0.8	0.9	0.559746	0	0.1381	0.3061
0.9	0.9	0.724875	0	0.6158	0.649

EPOCH = 300					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.1	0.1	0.074359	0.4913	0.2017	0.2881
0.2	0.1	0.083369	0.4904	0.2388	0.3155
0.3	0.1	0.08249	0.5275	0.2578	0.3333
0.4	0.1	0.085142	0.5202	0.2436	0.3253
0.5	0.1	0.104069	0.4507	0.1794	0.2822
0.6	0.1	0.118022	-0.1121	0.1949	0.3201
0.7	0.1	0.126893	0.317	0.3894	0.4325
0.8	0.1	0.143161	0.2604	0.3874	0.4337
0.9	0.1	0.156806	0.1522	0.2983	0.3714
0.1	0.2	0.074243	0.5021	0.2002	0.2856
0.2	0.2	0.077556	0.5256	0.2503	0.3225
0.3	0.2	0.082102	0.5285	0.2694	0.3461
0.4	0.2	0.857217	0.4797	0.2689	0.3633
0.5	0.2	0.107795	0.4331	0.1817	0.2878
0.6	0.2	0.011725	0.3696	0.2421	0.3187

EPOCH = 300					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.7	0.2	0.133784	0.2813	0.459	0.4961
0.8	0.2	0.147545	0.218	0.45	0.4913
0.9	0.2	0.15745	0.0979	0.4175	0.4667
0.1	0.3	0.074478	0.5112	0.199	0.2835
0.2	0.3	0.079104	0.5264	0.2646	0.3354
0.3	0.3	0.083361	0.5331	0.2849	0.3589
0.4	0.3	0.088147	0.4565	0.3064	0.4014
0.5	0.3	0.114475	0.3782	0.287	0.3445
0.6	0.3	0.128992	0.3339	0.2636	0.3335
0.7	0.3	0.141933	0.2556	0.5073	0.5418
0.8	0.3	0.15789	0.2311	0.51	0.5467
0.9	0.3	0.178753	0.1083	0.4907	0.5304
0.1	0.4	0.075041	0.5197	0.198	0.2819
0.2	0.4	0.082301	0.5358	0.2728	0.345
0.3	0.4	0.092575	0.4798	0.2934	0.3835
0.4	0.4	0.101057	0.3409	0.5133	0.594
0.5	0.4	0.141303	0.2162	0.282	0.4132
0.6	0.4	0.136687	0.2866	0.5227	0.5563
0.7	0.4	0.146452	0.1388	0.5678	0.6027
0.8	0.4	0.16719	0.0539	0.5983	0.6336
0.9	0.4	0.168984	0.0251	0.584	0.6223
0.1	0.5	0.075963	0.5275	0.198	0.281
0.2	0.5	0.086219	0.5079	0.3043	0.3712
0.3	0.5	0.098289	0.4231	0.3304	0.4254
0.4	0.5	0.110897	0.3425	0.5505	0.6289
0.5	0.5	0.141571	0.1963	0.4882	0.5209
0.6	0.5	0.150391	0.1883	0.5588	0.5937
0.7	0.5	0.168731	0.1136	0.6189	0.6546
0.8	0.5	0.172246	0.0391	0.6488	0.6852
0.9	0.5	0.186522	0.0113	0.6329	0.6689
0.1	0.6	0.077953	0.5315	0.1934	0.2777
0.2	0.6	0.094406	0.4574	0.3699	0.4343
0.3	0.6	0.126331	0.3272	0.5513	0.6483
0.4	0.6	0.141004	0.2226	0.4196	0.4701
0.5	0.6	0.161885	1.1615	0.4766	0.5135
0.6	0.6	0.171522	0.1193	0.5998	0.6367
0.7	0.6	0.180459	0.0568	0.6518	0.6889
0.8	0.6	0.19805	0.0409	0.6973	0.7326
0.9	0.6	0.213123	0.0169	0.739	0.7736

EPOCH = 300					
LEARNING RATE	MOMEN TUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.1	0.7	0.081655	0.5339	0.1825	0.2717
0.2	0.7	0.115809	0.4141	0.3889	0.4859
0.3	0.7	0.141965	0.3379	0.279	0.3608
0.4	0.7	0.154029	0.2316	0.2006	0.3275
0.5	0.7	0.192273	0.1838	0.6277	0.6614
0.6	0.7	0.209793	0.3039	0.6607	0.6908
0.7	0.7	0.212568	0.0574	0.6298	0.6673
0.8	0.7	0.243081	0.0297	0.7001	0.7368
0.9	0.7	0.260883	0.053	0.848	0.8863
0.1	0.8	0.094924	0.4954	0.1718	0.27
0.2	0.8	0.118805	0.4046	0.4788	0.5644
0.3	0.8	0.181055	0.1572	0.4727	0.5598
0.4	0.8	0.263492	0.068	0.6911	0.7245
0.5	0.8	0.319502	0.0364	1.0092	1.0537
0.6	0.8	0.259355	0.0585	0.7401	0.7743
0.7	0.8	0.312776	0.0798	0.4703	0.5114
0.8	0.8	0.336172	0.0387	0.5439	0.5794
0.9	0.8	0.366088	0.0606	0.8656	0.9049
0.1	0.9	0.120977	0.4806	0.1925	0.2818
0.2	0.9	0.166506	0.2752	0.457	0.4955
0.3	0.9	0.254326	0.1859	0.1602	0.3092
0.4	0.9	0.482275	0.031	0.6124	0.6457
0.5	0.9	0.666504	-0.0277	17,688	1.795
0.6	0.9	0.521299	-0.0085	1.0943	1.1362
0.7	0.9	0.598693	0.0082	0.1324	0.3078
0.8	0.9	0.559746	0.0172	0.1381	0.3061
0.9	0.9	0.724875	0	0.6158	0.649

EPOCH = 200					
LEARNING RATE	MOMEN TUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.1	0.1	0.084626	0.3394	0.2177	0.3171
0.2	0.1	0.08048	0.4887	0.2393	0.3161
0.3	0.1	0.085156	0.4921	0.3071	0.3726
0.4	0.1	0.091799	0.4803	0.2626	0.344
0.5	0.1	0.103865	0.419	0.2368	0.3158
0.6	0.1	0.117452	0.3214	0.2215	0.3107

EPOCH = 200					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.7	0.1	0.127405	0.2815	0.3838	0.43
0.8	0.1	0.141338	0.2403	0.3879	0.4357
0.9	0.1	0.166273	0.1236	0.347	0.4088
0.1	0.2	0.08092	0.4151	0.213	0.3065
0.2	0.2	0.080832	0.4999	0.2493	0.3222
0.3	0.2	0.08724	0.4978	0.3102	0.3794
0.4	0.2	0.094273	0.04748	0.2805	0.3614
0.5	0.2	0.108515	0.3878	0.2571	0.3289
0.6	0.2	0.121859	0.3134	0.2659	0.3381
0.7	0.2	0.134425	0.2676	0.4498	0.4892
0.8	0.2	0.144675	0.2009	0.4499	0.4922
0.9	0.2	0.168541	0.1232	0.4237	0.4707
0.1	0.3	0.078982	0.4541	0.2103	0.2979
0.2	0.3	0.081783	0.5049	0.2689	0.3373
0.3	0.3	0.089826	0.4942	0.3238	0.3947
0.4	0.3	0.097899	0.4659	0.3267	0.4047
0.5	0.3	0.119057	0.3129	0.3159	0.3695
0.6	0.3	0.130128	0.3078	0.2625	0.3353
0.7	0.3	0.142285	0.2471	0.4983	0.5353
0.8	0.3	0.155914	0.1209	0.5124	0.5506
0.9	0.3	0.161923	0.0643	0.4952	0.5355
0.1	0.4	0.07835	0.4791	0.2062	0.2911
0.2	0.4	0.08401	0.5078	0.2896	0.3554
0.3	0.4	0.097873	0.4612	0.3186	0.3999
0.4	0.4	0.106729	0.1818	0.4152	0.462
0.5	0.4	0.134766	0.2542	0.2465	0.367
0.6	0.4	0.138448	0.419	0.2368	0.3158
0.7	0.4	0.150371	0.2067	0.5501	0.5856
0.8	0.4	0.160642	0.043	0.6025	0.64
0.9	0.4	0.168183	0.0368	0.614	0.6521
0.1	0.5	0.078928	0.4962	0.2019	0.286
0.2	0.5	0.089067	0.4896	0.3142	0.3796
0.3	0.5	0.097756	0.4251	0.3522	0.4411
0.4	0.5	0.117212	0.3678	0.4949	0.5615
0.5	0.5	0.141698	0.1971	0.4793	0.5123
0.6	0.5	0.158275	0.2051	0.5675	0.6025
0.7	0.5	0.160297	0.1268	0.6077	0.6442
0.8	0.5	0.174115	0.042	0.6549	0.6918
0.9	0.5	0.185854	0.02	0.6802	0.7213

EPOCH = 200					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.1	0.6	0.080762	0.5117	0.1982	0.2821
0.2	0.6	0.996766	0.4399	0.3833	0.446
0.3	0.6	0.123027	0.332	0.5291	0.604
0.4	0.6	0.142867	0.1966	0.4135	0.4661
0.5	0.6	0.160595	0.1009	0.5293	0.5655
0.6	0.6	0.168669	0.1362	0.5838	0.6207
0.7	0.6	0.179608	0.0612	0.6559	0.6936
0.8	0.6	0.196291	0.0426	0.6951	0.7326
0.9	0.6	0.213581	0.027	0.741	0.7753
0.1	0.7	0.078982	0.4541	0.2103	0.2979
0.2	0.7	0.113557	0.3924	0.4317	0.5244
0.3	0.7	0.146503	0.3411	0.2786	0.3591
0.4	0.7	0.172524	0.0982	0.2333	0.3453
0.5	0.7	0.199996	0.1814	0.7482	0.7828
0.6	0.7	0.189077	0.1743	0.6824	0.7154
0.7	0.7	0.212249	0.0599	0.6332	0.6712
0.8	0.7	0.234627	0.0647	0.6821	0.716
0.9	0.7	0.260885	0.0571	0.8479	0.8863
0.1	0.8	0.100087	0.463	0.1856	0.2798
0.2	0.8	0.128251	0.304	0.611	0.662
0.3	0.8	0.168121	0.2408	0.7746	0.837
0.4	0.8	0.291705	0.0951	0.6674	0.7006
0.5	0.8	0.298003	0.1738	1.0199	1.0629
0.6	0.8	0.301483	0.0588	0.7477	0.7821
0.7	0.8	0.31389	0.0366	0.4716	0.5125
0.8	0.8	0.336172	0.0392	0.5439	0.5794
0.9	0.8	0.366088	0.0605	0.8656	0.9049
0.1	0.9	0.143734	0.4134	0.1732	0.2815
0.2	0.9	0.172743	1.1818	0.4152	0.462
0.3	0.9	0.254234	0.0954	0.1604	0.3091
0.4	0.9	0.482286	-0.0124	0.6125	0.6458
0.5	0.9	0.666504	-0.0285	1.7688	1.795
0.6	0.9	0.521299	-0.0085	1.0942	1.1362
0.7	0.9	0.598693	0.0082	0.1324	0.3078
0.8	0.9	0.055975	0	0.1381	0.3061
0.9	0.9	0.724875	0	0.6158	0.649

EPOCH = 100					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.1	0.1	0.088464	0.2644	0.2224	0.3246
0.2	0.1	0.092637	0.2733	0.2533	0.3414
0.3	0.1	0.095227	0.3298	0.3096	0.3774
0.4	0.1	0.098531	0.3551	0.3804	0.4409
0.5	0.1	0.1083	0.3342	0.4301	0.4731
0.6	0.1	0.116798	0.332	0.3282	0.3869
0.7	0.1	0.126918	0.2814	0.4072	0.4554
0.8	0.1	0.140152	0.1995	0.4053	0.4542
0.9	0.1	0.147713	0.1119	0.3767	0.4321
0.1	0.2	0.089115	0.2643	0.2242	0.3256
0.2	0.2	0.092928	0.2975	0.2636	0.3458
0.3	0.2	0.094934	0.4139	0.1808	0.2826
0.4	0.2	0.100391	0.3597	0.4226	0.4825
0.5	0.2	0.110594	0.3375	0.3741	0.4253
0.6	0.2	0.11959	0.2802	0.3267	0.3836
0.7	0.2	0.13249	0.2297	0.4605	0.5019
0.8	0.2	0.144502	0.1606	0.472	0.5143
0.9	0.2	0.154705	0.0629	0.4611	0.5057
0.1	0.3	0.089872	0.2648	0.2247	0.3259
0.2	0.3	0.092586	0.3421	0.2753	0.3508
0.3	0.3	0.096189	0.3791	0.3855	0.4456
0.4	0.3	0.10454	0.3564	0.4578	0.5164
0.5	0.3	0.117935	0.3226	0.3786	0.4282
0.6	0.3	0.129889	0.2724	0.353	0.4054
0.7	0.3	0.139499	0.2032	0.5149	0.5534
0.8	0.3	0.147898	0.0902	0.5439	0.5834
0.9	0.3	0.162601	0.0392	0.541	0.5807
0.1	0.4	0.090637	0.2681	0.2241	0.3253
0.2	0.4	0.092503	0.3834	0.2987	0.3668
0.3	0.4	0.099899	0.3793	0.4249	0.484
0.4	0.4	0.111168	0.3361	0.4731	0.5305
0.5	0.4	0.124809	0.3638	0.4176	0.4605
0.6	0.4	0.140236	0.247	0.5151	0.553
0.7	0.4	0.153229	0.1484	0.5784	0.6165
0.8	0.4	0.158804	0.4888	0.621	0.6597
0.9	0.4	0.173265	0.0341	0.5959	0.6337
0.1	0.5	0.091139	0.2853	0.2225	0.3221
0.2	0.5	0.094837	0.4112	0.3517	0.413
0.3	0.5	0.106342	0.3853	0.4893	0.5494

EPOCH = 100					
LEARNING RATE	MOMENTUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.4	0.5	0.121608	0.3058	0.4755	0.5351
0.5	0.5	0.14392	0.2378	0.4751	0.5102
0.6	0.5	0.157963	0.3236	0.3786	0.4282
0.7	0.5	0.159106	0.0663	0.6431	0.6819
0.8	0.5	0.172581	0.0482	0.6736	0.7125
0.9	0.5	0.188462	0.0307	0.6674	0.7051
0.1	0.6	0.090757	0.3493	0.2152	0.3115
0.2	0.6	0.101301	0.3981	0.4251	0.4847
0.3	0.6	0.116158	0.3575	0.4894	0.5549
0.4	0.6	0.145535	0.2587	0.4553	0.505
0.5	0.6	0.16944	0.268	0.5346	0.57
0.6	0.6	0.193134	0.1102	0.6282	0.665
0.7	0.6	0.178111	0.0671	0.664	0.7031
0.8	0.6	0.194394	0.0511	0.6997	0.7385
0.9	0.6	0.212949	0.0153	0.8213	0.8679
0.1	0.7	0.091868	0.4063	0.2064	0.2965
0.2	0.7	0.120271	0.401	0.5104	0.5775
0.3	0.7	0.140106	0.3562	0.3195	0.4239
0.4	0.7	0.189891	0.2059	0.551	0.5956
0.5	0.7	0.197298	0.1947	0.6713	0.708
0.6	0.7	0.20492	0.1579	0.6393	0.6757
0.7	0.7	0.209619	0.0747	0.6189	0.6565
0.8	0.7	0.248472	0.0291	0.6935	0.7268
0.9	0.7	0.260886	0.059	0.8479	0.8863
0.1	0.8	0.988935	0.4139	0.1808	0.2826
0.2	0.8	0.143176	0.3626	0.5151	0.5828
0.3	0.8	0.186378	0.2682	0.3431	0.4376
0.4	0.8	0.246991	0.0746	0.5932	0.6308
0.5	0.8	0.258702	0.0651	0.8267	0.8649
0.6	0.8	0.290335	0.0911	0.7351	0.7695
0.7	0.8	0.313965	0.0146	0.4715	0.5125
0.8	0.8	0.336172	0.0398	0.5439	0.5794
0.9	0.8	0.366088	0.0604	0.8656	0.9049
0.1	0.9	0.126736	0.376	0.1565	0.2839
0.2	0.9	0.174922	0.2623	0.5917	0.6356
0.3	0.9	0.254247	0.1575	0.1601	0.3091
0.4	0.9	0.482294	-0.0357	0.6125	0.6457
0.5	0.9	0.666504	-0.0294	1.7688	1.795
0.6	0.9	0.521299	-0.0086	1.0942	1.1362

EPOCH = 100					
LEARNING RATE	MOMEN TUM	ERROR OF EPOCH	CORRELATION COEFICIENT	MSE	RMSE
0.7	0.9	0.598693	0.0082	0.1324	0.3078
0.8	0.9	0.559746	0	0.1381	0.3061
0.9	0.9	0.724875	0	0.6158	0.649

Hasil percobaan Hidden Layer dari N hingga $3N$ pada input layer yang terdiri atas 12 node dan leraning rate 0.1, momentum 0.9, epoch 500.

hidden layer	RMSE
3	0.0746
6	0.0647
9	0.0593
12	0.0626
13	0.0579
14	0.0746
15	0.0589
16	0.0581
17	0.0614
18	0.0757
19	0.0585
20	0.0571
21	0.0666
22	0.0581
23	0.0553
24	0.0573
25	0.0616
26	0.0636
27	0.0621
28	0.0568
29	0.0621
30	0.079
31	0.0669
32	0.0642
33	0.0644
34	0.0611
35	0.0602
36	0.0653

LAMPIRAN D

Lampiran D berisi data prediksi dari hasil model terbaik ANN.

DATA TRAINING				
tahun	bulan	residu	prediksi	error
2002	Jan		0.327	-0.327
2002	Feb	0.032	-0.016	-0.031
2002	Mar	0.032	0.041	0.026
2002	Apr	0.032	0.011	-0.004
2002	May	1.107	-0.225	-0.003
2002	Jun	0.038	0.006	0.003
2002	Jul	0.012	0.018	0.014
2002	Aug	-0.828	0.179	-0.052
2002	Sep	0.996	-0.223	-0.006
2002	Oct	0.191	-0.093	-0.091
2002	Nov	0.035	-0.036	-0.039
2002	Dec	0.15	0.084	0.085
2003	Jan	-0.939	0.207	-0.029
2003	Feb	1.094	-0.062	0.159
2003	Mar	0.089	0.017	0.016
2003	Apr	-0.01	0.005	0
2003	May	0.057	-0.018	-0.021
2003	Jun	-0.805	0.16	-0.071
2003	Jul	0.032	0.007	-0.008
2003	Aug	0.032	0.054	0.038
2003	Sep	0.032	-0.022	-0.037
2003	Oct	0.979	-0.081	0.136
2003	Nov	-0.852	0.112	-0.121
2003	Dec	0.032	0.073	0.058
2004	Jan	0.032	0.07	0.055
2004	Feb	0.032	-0.058	-0.073
2004	Mar	0.032	0.002	-0.013
2004	Apr	0.032	0.002	-0.013
2004	May	0.032	-0.006	-0.021
2004	Jun	0.032	0.072	0.057
2004	Jul	0.032	-0.001	-0.016
2004	Aug	0.032	0.009	-0.006
2004	Sep	0.032	-0.012	-0.027
2004	Oct	0.032	0.049	0.034
2004	Nov	0.032	0.063	0.048

DATA TRAINING				
tahun	bulan	residu	prediksi	error
2004	Dec	0.032	0.035	0.02
2005	Jan	0.032	0.012	-0.003
2005	Feb	0.032	-0.043	-0.058
2005	Mar	0.032	-0.002	-0.017
2005	Apr	0.032	0.004	-0.011
2005	May	0.032	-0.003	-0.018
2005	Jun	0.032	0.02	0.005
2005	Jul	0.032	-0.001	-0.017
2005	Aug	0.032	-0.002	-0.017
2005	Sep	0.032	-0.011	-0.026
2005	Oct	0.032	0.012	-0.004
2005	Nov	0.032	0.009	-0.006
2005	Dec	0.032	-0.006	-0.021
2006	Jan	0.032	-0.001	-0.016
2006	Feb	0.032	-0.031	-0.046
2006	Mar	0.032	-0.002	-0.017
2006	Apr	0.032	0.007	-0.008
2006	May	0.032	0	-0.015
2006	Jun	0.032	0.01	-0.005
2006	Jul	0.032	-0.001	-0.016
2006	Aug	0.032	-0.004	-0.019
2006	Sep	0.032	-0.01	-0.025
2006	Oct	0.032	-0.001	-0.017
2006	Nov	0.032	-0.013	-0.029
2006	Dec	0.032	-0.02	-0.035
2007	Jan	0.032	-0.004	-0.019
2007	Feb	1.119	-0.023	0.199
2007	Mar	-0.098	-0.002	-0.011
2007	Apr	0.201	0.011	0.015
2007	May	-0.023	0.003	-0.004
2007	Jun	0.167	0.012	0.015
2007	Jul	0.198	0.001	0.004
2007	Aug	0.101	-0.004	-0.005
2007	Sep	0.095	-0.009	-0.01
2007	Oct	-0.1	-0.004	-0.014
2007	Nov	0.205	-0.021	-0.016
2007	Dec	0.021	-0.021	-0.025
2008	Jan	0.091	-0.004	-0.005
2008	Feb	-0.788	-0.019	-0.248
2008	Mar	0.032	-0.001	-0.016
2008	Apr	0.032	0.016	0.001

DATA TRAINING				
tahun	bulan	residu	prediksi	error
2008	May	0.032	0.006	-0.009
2008	Jun	0.032	0.016	0.001
2008	Jul	0.032	0.003	-0.013
2008	Aug	0.032	-0.004	-0.019
2008	Sep	0.032	-0.008	-0.023
2008	Oct	0.032	-0.004	-0.019
2008	Nov	0.032	-0.024	-0.039
2008	Dec	0.032	-0.019	-0.034
2009	Jan	0.032	-0.003	-0.018
2009	Feb	0.032	-0.016	-0.032
2009	Mar	0.032	0	-0.015
2009	Apr	0.032	0.021	0.006
2009	May	0.032	0.01	-0.005
2009	Jun	0.032	0.022	0.007
2009	Jul	0.032	0.004	-0.011
2009	Aug	0.032	-0.003	-0.019
2009	Sep	0.032	-0.006	-0.022
2009	Oct	0.032	-0.003	-0.018
2009	Nov	0.032	-0.026	-0.041
2009	Dec	0.032	-0.018	-0.034
2010	Jan	0.032	-0.002	-0.017
2010	Feb	0.032	-0.016	-0.031
2010	Mar	0.032	0.002	-0.013
2010	Apr	0.032	0.028	0.013
2010	May	0.032	0.015	0
2010	Jun	0.032	0.029	0.014
2010	Jul	0.032	0.006	-0.009
2010	Aug	0.032	-0.003	-0.018
2010	Sep	0.032	-0.005	-0.02
2010	Oct	0.032	-0.001	-0.016
2010	Nov	0.032	-0.03	-0.045
2010	Dec	0.975	-0.018	0.198
2011	Jan	0.211	0	0.003
2011	Feb	0.058	-0.017	-0.019
2011	Mar	0.176	0.005	0.006
2011	Apr	0.151	0.036	0.037
2011	May	-0.251	0.02	0.004
2011	Jun	-0.692	0.038	-0.186
2011	Jul	0.032	0.008	-0.007
2011	Aug	0.032	-0.003	-0.018
2011	Sep	1.112	-0.003	0.218

DATA TRAINING				
tahun	bulan	residu	prediksi	error
2011	Oct	0.155	0.001	0.002
2011	Nov	0.071	-0.034	-0.035
2011	Dec	0.151	-0.019	-0.018
2012	Jan	0.012	0.002	-0.002
2012	Feb	0.125	-0.02	-0.02
2012	Mar	0.16	0.008	0.008
2012	Apr	0.052	0.046	0.044
2012	May	-0.67	0.027	-0.067
2012	Jun	-0.241	0.048	-0.101
2012	Jul	0.032	0.009	-0.006
2012	Aug	0.032	-0.004	-0.019
2012	Sep	0.032	-0.001	-0.016
2012	Oct	0.032	0.004	-0.012
2012	Nov	0.908	-0.04	0.173
2012	Dec	0.294	-0.019	-0.012
2013	Jan	0.174	0.004	0.005
2013	Feb	0.108	-0.025	-0.025
2013	Mar	-0.126	0.011	0.002
2013	Apr	-0.819	0.058	-0.174
2013	May	0.032	0.034	0.019
2013	Jun	0.032	0.061	0.046
2013	Jul	0.032	0.008	-0.007
2013	Aug	0.032	-0.007	-0.022
2013	Sep	0.032	0.002	-0.014
2013	Oct	0.032	0.006	-0.009
2013	Nov	0.032	-0.049	-0.064
2013	Dec	0.032	-0.02	-0.035
2014	Jan	0.032	0.007	-0.008
2014	Feb	0.032	-0.034	-0.049
2014	Mar	0.032	0.015	0
2014	Apr	0.032	0.072	0.057
2014	May	0.032	0.043	0.028
2014	Jun	0.032	0.077	0.062
2014	Jul	0.032	0.004	-0.011
2014	Aug	0.032	-0.013	-0.029
2014	Sep	0.032	0.005	-0.01

DATA TESTING				
tahun	bulan	residu	prediksi	eror
2014	Oct	0.032	-0.113	0.113
2014	Nov	1.101	-0.222	-0.006
2014	Dec	0.038	-0.079	-0.083
2015	Jan	-0.904	0.192	-0.044
2015	Feb	0.032	-0.031	-0.053
2015	Mar	0.032	-0.071	-0.092
2015	Apr	0.032	0.023	0.001
2015	May	0.032	-0.055	-0.077
2015	Jun	0.032	0.006	-0.015
2015	Jul	0.032	-0.014	-0.036
2015	Aug	0.032	0.001	-0.02
2015	Sep	0.032	-0.076	-0.097
2015	Oct	0.032	0.018	-0.004
2015	Nov	1.032	-0.23	-0.017
2015	Dec	0.078	0.007	0.005
2016	Jan	0.208	0.027	0.03
2016	Feb	0.123	0.008	0.007
2016	Mar	0.165	0.008	0.009
2016	Apr	0.033	0.013	0.011
2016	May	-0.275	0.007	-0.014
2016	Jun	0.319	0.009	0.021
2016	Jul	-0.681	0.082	-0.053
2016	Aug	-0.127	0.01	-0.101
2016	Sep	0.032	-0.034	-0.056
2016	Oct	0.032	0.01	-0.011
2016	Nov	0.032	0.002	-0.019
2016	Dec	0.032	0.008	-0.014

Halaman ini sengaja dikosongkan

LAMPIRAN E

Lampiran E berisi data hasil peramalan kedepan dengan metode ARIMA-NN.

tahun	bulan	aktual	prediksi	residu prediksi
2002	Jan	0	35	-34.73881294
2002	Feb	0	31	-30.67871959
2002	Mar	0	29	-29.37470618
2002	Apr	0	30	-30.09149827
2002	May	49700	49730	-30.06873672
2002	Jun	24794	24824	-29.93057887
2002	Jul	10600	10630	-29.6700443
2002	Aug	0	31	-31.10125285
2002	Sep	15800	15830	-30.13679717
2002	Oct	41275	41307	-31.81501833
2002	Nov	20450	20481	-30.84305282
2002	Dec	34600	34628	-27.73360158
2003	Jan	0	31	-30.63696893
2003	Feb	43243	43268	-25.12907625
2003	Mar	36900	36930	-29.6216411
2003	Apr	12021	12051	-30
2003	May	8500	8530	-30.4672333
2003	Jun	0	31	-31.45992092
2003	Jul	0	30	-30.18179909
2003	Aug	0	29	-29.06720429
2003	Sep	0	31	-30.80236575
2003	Oct	13500	13526	-26.01437454
2003	Nov	0	32	-32.30809415
2003	Dec	0	29	-28.52599603
2004	Jan	0	29	-28.60955701
2004	Feb	0	31	-31.49643903
2004	Mar	0	30	-30.29302
2004	Apr	0	30	-30.29302
2004	May	0	30	-30.4672333
2004	Jun	0	29	-28.55394548
2004	Jul	0	30	-30.35888374
2004	Aug	0	30	-30.13679717
2004	Sep	0	31	-30.59494712
2004	Oct	0	29	-29.17109343
2004	Nov	0	29	-28.80122149
2004	Dec	0	30	-29.52385888
2005	Jan	0	30	-30.06873672

tahun	bulan	aktual	prediksi	residu prediksi
2005	Feb	0	31	-31.21685713
2005	Mar	0	30	-30.38069523
2005	Apr	0	30	-30.24875027
2005	May	0	30	-30.40243566
2005	Jun	0	30	-29.88391381
2005	Jul	0	30	-30.38069523
2005	Aug	0	30	-30.38069523
2005	Sep	0	31	-30.57383387
2005	Oct	0	30	-30.09149827
2005	Nov	0	30	-30.13679717
2005	Dec	0	30	-30.4672333
2006	Jan	0	30	-30.35888374
2006	Feb	0	31	-30.98341747
2006	Mar	0	30	-30.38069523
2006	Apr	0	30	-30.18179909
2006	May	0	30	-30.33700089
2006	Jun	0	30	-30.11418499
2006	Jul	0	30	-30.35888374
2006	Aug	0	30	-30.42410529
2006	Sep	0	31	-30.55265203
2006	Oct	0	30	-30.38069523
2006	Nov	0	31	-30.63696893
2006	Dec	0	31	-30.76141591
2007	Jan	0	30	-30.42410529
2007	Feb	56100	56123	-23.39717593
2007	Mar	7450	7480	-30.24875027
2007	Apr	21000	21030	-29.64588308
2007	May	6700	6730	-30.09149827
2007	Jun	13489	13519	-29.64588308
2007	Jul	37650	37680	-29.90728498
2007	Aug	37000	37030	-30.11418499
2007	Sep	34100	34130	-30.22650638
2007	Oct	5000	5030	-30.3150464
2007	Nov	14400	14430	-30.35888374
2007	Dec	7200	7231	-30.55265203
2008	Jan	7175	7205	-30.11418499
2008	Feb	0	34	-33.96940806
2008	Mar	0	30	-30.35888374
2008	Apr	0	30	-29.97693608
2008	May	0	30	-30.20418942
2008	Jun	0	30	-29.97693608
2008	Jul	0	30	-30.29302

tahun	bulan	aktual	prediksi	residu prediksi
2008	Aug	0	30	-30.42410529
2008	Sep	0	31	-30.51008148
2008	Oct	0	30	-30.42410529
2008	Nov	0	31	-30.84305282
2008	Dec	0	31	-30.7408418
2009	Jan	0	30	-30.40243566
2009	Feb	0	31	-30.6994939
2009	Mar	0	30	-30.33700089
2009	Apr	0	30	-29.86046506
2009	May	0	30	-30.11418499
2009	Jun	0	30	-29.83693842
2009	Jul	0	30	-30.24875027
2009	Aug	0	30	-30.42410529
2009	Sep	0	30	-30.48869223
2009	Oct	0	30	-30.40243566
2009	Nov	0	31	-30.88347914
2009	Dec	0	31	-30.7408418
2010	Jan	0	30	-30.38069523
2010	Feb	0	31	-30.67871959
2010	Mar	0	30	-30.29302
2010	Apr	0	30	-29.69412508
2010	May	0	30	-30
2010	Jun	0	30	-29.6700443
2010	Jul	0	30	-30.20418942
2010	Aug	0	30	-30.40243566
2010	Sep	0	30	-30.44570441
2010	Oct	0	30	-30.35888374
2010	Nov	0	31	-30.96355766
2010	Dec	12945	12968	-23.44373406
2011	Jan	41610	41640	-29.93057887
2011	Feb	26099	26130	-30.42410529
2011	Mar	58115	58145	-29.86046506
2011	Apr	97544	97573	-29.09330871
2011	May	2997	3027	-29.90728498
2011	Jun	0	33	-33.23490975
2011	Jul	0	30	-30.15933511
2011	Aug	0	30	-30.40243566
2011	Sep	52450	52472	-22.47786316
2011	Oct	92089	92119	-29.9537958
2011	Nov	60738	60768	-30.76141591
2011	Dec	101599	101629	-30.40243566
2012	Jan	34934	34964	-30.04590002

tahun	bulan	aktual	prediksi	residu prediksi
2012	Feb	44502	44532	-30.44570441
2012	Mar	82830	82860	-29.81333356
2012	Apr	45010	45039	-28.90870249
2012	May	100	131	-31.38619172
2012	Jun	0	32	-31.98445544
2012	Jul	0	30	-30.13679717
2012	Aug	0	30	-30.42410529
2012	Sep	0	30	-30.35888374
2012	Oct	0	30	-30.27092138
2012	Nov	6981	7005	-24.55221896
2012	Dec	51356	51386	-30.27092138
2013	Jan	112036	112066	-29.88391381
2013	Feb	110716	110747	-30.55265203
2013	Mar	9677	9707	-29.9537958
2013	Apr	0	33	-33.0769591
2013	May	0	30	-29.54842723
2013	Jun	0	29	-28.8551453
2013	Jul	0	30	-30.15933511
2013	Aug	0	30	-30.48869223
2013	Sep	0	30	-30.3150464
2013	Oct	0	30	-30.20418942
2013	Nov	0	31	-31.33028144
2013	Dec	0	31	-30.76141591
2014	Jan	0	30	-30.18179909
2014	Feb	0	31	-31.0426173
2014	Mar	0	30	-30
2014	Apr	0	29	-28.55394548
2014	May	0	29	-29.32431663
2014	Jun	0	28	-28.41323111
2014	Jul	0	30	-30.24875027
2014	Aug	0	31	-30.63696893
2014	Sep	0	30	-30.22650638
2014	Oct	0	27	-26.82860018
2014	Nov	46248	46278	-30.13679717
2014	Dec	23387	23419	-31.67563437
2015	Jan	0	31	-30.94363417
2015	Feb	0	31	-31.12067377
2015	Mar	0	32	-31.83219897
2015	Apr	0	30	-29.97693608
2015	May	0	32	-31.56879103
2015	Jun	0	30	-30.33700089
2015	Jul	0	31	-30.78192381

tahun	bulan	aktual	prediksi	residu prediksi
2015	Aug	0	30	-30.44570441
2015	Sep	0	32	-31.91730844
2015	Oct	0	30	-30.09149827
2015	Nov	22654	22685	-30.38069523
2015	Dec	18269	18299	-29.88391381
2016	Jan	57288	57317	-29.27358652
2016	Feb	70093	70122	-29.83693842
2016	Mar	137047	137077	-29.78965018
2016	Apr	56919	56949	-29.74204659
2016	May	1750	1780	-30.3150464
2016	Jun	13541	13571	-29.49920811
2016	Jul	40	71	-31.12067377
2016	Aug	0	32	-31.98445544
2016	Sep	0	31	-31.17856708
2016	Oct	0	30	-30.24875027
2016	Nov	0	30	-30.42410529
2018	des	0	30	-30.3150464
2017	jan	0	30	-29.97693608
2017	feb	0	30	-30.02298788
2017	mar	0	30	-30
2017	apr	0	30	-30
2017	mei	0	30	-30
2017	jun	0	30	-30.02298788
2017	jul	0	30	-30.04590002
2017	agu	0	30	-30.06873672
2017	sep	0	30	-30.02298788
2017	okt	0	30	-30.02298788
2017	nov	0	30	-30.02298788
2017	des	0	30	-30.02298788
2018	jan	0	30	-29.9537958
2018	feb	0	30	-29.9537958
2018	mar	0	30	-29.9537958
2018	apr	0	30	-29.9537958
2018	mei	0	30	-29.9537958
2018	jun	0	30	-29.9537958
2018	jul	0	30	-29.9537958
2018	agu	0	30	-29.9537958
2018	sep	0	30	-29.9537958
2018	okt	0	30	-29.9537958
2018	nov	0	30	-29.9537958
2018	des	0	30	-29.9537958