



TUGAS AKHIR - SS 141501

**PEMODELAN DATA CURAH HUJAN
DI KABUPATEN BANYUWANGI DENGAN METODE
ARIMA DAN *RADIAL BASIS FUNCTION*
*NEURAL NETWORK***

**NOVELINA PURBA
NRP 1314 105 014**

**Dosen Pembimbing
Dr. Brodjol Sutijo S.U., M.Si**

**PIROGRAM STUDI S1
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2016**



FINAL PROJECT - SS 141501

**MODELING RAINFALL IN DISTRICT
BANYUWANGI USING ARIMA AND RADIAL
BASIS FUNCTION NEURAL NETWORK**

**NOVELINA PURBA
NRP 1314 105 014**

**Supervisor
Dr. Bordjol Sutijo S.U., M.Si**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCE
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2016**

LEMBAR PENGESAHAN

PEMODELAN DATA CURAH HUJAN DI KABUPATEN
BANYUWANGI DENGAN ARIMA DAN RADIAL BASIS
FUNTION NEURAL NETWORK

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada
Program Studi S-1 Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

NOVELINA PURBA
NRP. 1314 105 014

Disetujui oleh Pembimbing Tugas Akhir

Dr. Brodjol Sutijo S.U., M.Si
NIP. 19660125 199002 1 001

()

Mengetahui

Ketua Jurusan Statistika FMIPA-ITS



Dr. Suhartono

NIP. 19710929 199512 1 001

SURABAYA, JULI 2016

**LEMBAR PERNYATAAN
PERSETUJUAN PUBLIKASI KARYA ILMIAH
UNTUK KEPENTINGAN AKADEMIS**

Sebagai mahasiswa Institut Teknologi Sepuluh Nopember Surabaya, yang bertanda tangan di bawah ini saya :

Nama : Novelina Purba
Nrp. : 1314105014
Jurusan / Fak. : Statistika / MIPA
Alamat kontak : Asrama Mahasiswa ITS
a. Email : novelinagirsang@gmail.com
b. Telp/HP : 0853 6012 5150

Menyatakan bahwa semua data yang saya *upload* di Digital Library ITS merupakan hasil final (revisi terakhir) dari karya ilmiah saya yang sudah disahkan oleh dosen penguji. Apabila dikemudian hari ditemukan ada ketidaksesuaian dengan kenyataan, maka saya bersedia menerima sanksi.

Demi perkembangan ilmu pengetahuan, saya menyetujui untuk memberikan **Hak Bebas Royalti Non-Eksklusif (*Non-Exclusive Royalti-Free Right*)** kepada Institut Teknologi Sepuluh Nopember Surabaya atas karya ilmiah saya yang berjudul :

Pemodelan Data Curah Hujan Di Kabupaten Banyuwangi dengan Metode ARIMA dan Radial Basis Function Neural Network

Dengan Hak Bebas Royalti Non-Eksklusif ini, Institut Teknologi Sepuluh Nopember Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (*database*), mendistribusikannya, dan menampilkan/mempublikasikannya di internet atau media lain untuk kepentingan akademis tanpa meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta. Saya bersedia menanggung secara pribadi, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya Ilmiah saya ini tanpa melibatkan pihak Institut Teknologi Sepuluh Nopember Surabaya.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Surabaya
Pada tanggal : Juli 2016
Yang menyatakan,

Dosen Pembimbing 1


Dr. Pratiwi Sutjipto, S.U., M.Si


Novelina Purba

NIP. 19660125 199002 1 001

Nrp. 1314105014

KETERANGAN :

Tanda tangan pembimbing wajib dibubuhi stempel jurusan.

Form dicetak dan diserahkan di bagian Pengadaan saat mengumpulkan hard copy TA/Tesis/Disertasi.

**Pemodelan Data Curah Hujan Di Kabupaten Banyuwangi
dengan Metode ARIMA dan *Radial Basis Function Neural Network***

Nama Mahasiswa : Novelina Purba
NRP : 1314 105 014
Program Studi : S1
Jurusan : Statistika
Dosen Pembimbing : Dr. Brodjol Sutijo S.U., M.Si

ABSTRAK

Curah hujan merupakan salah satu komponen lingkungan pemegang peranan penting dalam budidaya tanaman. Bagi Kabupaten Banyuwangi jumlah curah hujan di daerah ini sangat penting dalam menentukan keberhasilan produksi padi. Mengingat Kabupaten Banyuwangi merupakan salah satu lumbung padi Jawa Timur, maka perencanaan waktu tanam padi sangat dibutuhkan. Perencanaan waktu tanam bergantung pada curah hujan, sehingga perlu dilakukan peramalan curah hujan di Kabupaten Banyuwangi. Penelitian ini menggunakan metode ARIMA dan RBFNN untuk memodelkan curah hujan di Kabupaten Banyuwangi. Model ARIMA dapat menangkap pola linier pada data curah hujan, sedangkan model RBFNN dimaksudkan untuk menangkap pola non linier pada data. Data yang digunakan dalam penelitian ini data curah hujan hasil pengamatan dari Stasiun Meteorologi Banyuwangi sehingga model yang dihasilkan hanya berlaku bagi daerah dengan radius 20 km dari tempat pengambilan data, yaitu Stasiun Meteorologi Banyuwangi. Model RBFNN dalam penelitian ini menghasilkan nilai *Mean Square Error* (MSE) sebesar 300,185, sementara model ARIMA menghasilkan nilai MSE sebesar 344,658. Berdasarkan perbandingan nilai MSE dari kedua model tersebut dinyatakan bahwa dalam penelitian ini model RBFNN lebih baik dibandingkan model ARIMA.

Kata kunci: ARIMA, RBFNN, Curah Hujan, Banyuwangi

(Halaman ini sengaja dikosongkan)

Modeling Rainfall In District Banyuwangi Using ARIMA and Radial Basis Function Neural Network

Student Name : Novelina Purba
NRP : 1314 105 014
Programme : Undergraduate
Department : Statistics
Supervisor : Dr. Brodjol Sutijo S. U., M.Si

ABSTRACT

Rainfall is a very important role in the cultivation of plants. For District Banyuwangi amount of rainfall in this area is very important in determining the success of rice production. Planning the rice planting in Banyuwangi is needed because Banyuwangi is one of East Java's rice barns. Planning the rice-planting time depends on rainfall, so it is necessary to forecast rainfall in District Banyuwangi. This study uses ARIMA and Radial Basis Function Neural Network (RBFNN) for modeling rainfall in Banyuwangi. ARIMA model can capture the linear pattern on rainfall data, while RBFNN models intended to capture the non-linear patterns in the data. The data in this study is the rainfall data taken from Banyuwangi Meteorological Station so that the model applies only to the area within a radius of 20 km from the Meteorological Station Banyuwangi. MSE value of RBFNN model is 300,185 and MSE of ARIMA model is 34,658. Based on the MSE values of both models, in this study, RBFNN model is better than ARIMA model.

Keywords : ARIMA, RBFNN, Rainfall, Banyuwangi

(Halaman ini sengaja dikosongkan)

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
TITLE PAGE	ii
LEMBAR PENGESAHAN.....	iii
ABSTRAK	v
ABSTRACT.....	vii
KATA PENGANTAR.....	ix
DAFTAR ISI.....	xi
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL.....	xv
DAFTAR LAMPIRAN	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Penelitian	3
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	4
BAB II TIJAUAN PUSTAKA	5
2.1. Peramalan.....	5
2.2. Model Autoregressive Integrated Moving Average (ARIMA)	5
2.2.1 .Model ARIMA Non Musiman	6
2.2.2 .Model ARIMA Musiman.	6
2.3.. Identifikasi Model ARIMA	7
2.3.1 .Stasioner	7
2.3.2 .Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF).	8
2.3.3 .Estimasi Parameter.....	10
2.3.4 .Pengujian Signifikansi Parameter.....	11
2.3.5 Validasi Model dan Pemilihan Model Terbaik.....	11
2.4.. Uji Linieritas	13

Halaman

2.5.. Jaringan Saraf	14
2.5.1. Jaringan Saraf Biologi.....	14
2.5.2. Jaringan Saraf Tiruan.....	15
2.5.3. Kerangka Jaringan Saraf Tiruan.....	15
2.5.4. Arsitektur Jaringan Saraf Tiruan.....	16
2.5.5. Metode Pembelajaran dan Pelatihan	18
2.5.6. Jaringan Saraf Tiruan <i>Radial Basis</i> <i>Function</i> (RBF).....	18
BAB III METODOLOGI PENELITIAN.....	21
3.1 Sumber Data.....	21
3.2 Variabel Penelitian	21
3.3 Metode Analisis Data	21
3.4 Diagram Alir	22
BAB IV ANALISIS DAN PEMBAHASAN.....	25
4.1 Deskriptif Data Curah Hujan Kabupaten Banyuwangi.....	25
4.2 Pemodelan Data Curah Hujan Kabupaten Banyuwangi dengan ARIMA	28
4.2.1. Pendugaan Model ARIMA	28
4.2.2. Pengujian Asumsi Nilai Residual <i>White Noise</i> dan Berdistribusi Normal.....	33
4.2.3. Pemilihan Model ARIMA Terbaik	36
4.3 Uji Linieritas Data	37
4.4 Pemodelan dengan RBFNN.....	38
4.4.1. Penentuan Input RBFNN	39
4.4.2. Penentuan Jaringan Optimum	39
4.5 Perbandingan ARIMA dan RBFNN	43
4.6 Peramalan Curah Hujan di Kabupaten Banyuwangi.....	44
BAB V KESIMPULAN DAN SARAN.....	49
5.1 Kesimpulan	49
5.2 Saran	50
DAFTAR PUSTAKA	51

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Jaringan Saraf Biologis	14
Gambar 2.2 Arsitektur Jaringan Lapis Tunggal	16
Gambar 2.3 Arsitektur Jaringan Lapis Banyak	17
Gambar 2.4 Arsitektur Jaringan Lapis Kompetitif	17
Gambar 2.5 Arsitektur RBFNN	18
Gambar 3.1 Diagram Alir Penelitian Model ARIMA dan RBFNN	23
Gambar 4.1 Sebaran Data Curah Hujan Per Tahun Kab. Banyuwangi Tahun 2011-2015.....	26
Gambar 4.2 <i>Box Plot</i> Data Curah Hujan Bulanan Kabupaten Banyuwangi.....	27
Gambar 4.3 <i>Time Series Plot</i> Data Curah Hujan Kab. Banyuwangi.....	29
Gambar 4.4 <i>Box-cox Plot</i> Data Curah Hujan Kabupaten Banyuwangi.....	29
Gambar 4.5 <i>Box-cox Plot</i> Data Curah Hujan Kabupaten Banyuwangi Setelah Transformasi	30
Gambar 4.6 ACF Curah Hujan Kab.Banyuwangi	31
Gambar 4.7 (a)ACF dan (b) PACF Curah Hujan Kab. Banyuwangi Setelah Dilakukan Differencing.....	32
Gambar 4.8 Uji Normalitas Nilai Residual (a) ARIMA (1,1,0)(0,0,1) ¹⁵ , (b) ARIMA (0,1,1)(0,0,1) ¹⁵ , dan (c) ARIMA (2,1,0)(0,0,1) ¹⁵	35
Gambar 4.9 Data Aktual dan Peramalan dengan ARIMA (0,1,1)(0,0,1) ¹⁵	37
Gambar 4.10 <i>Scatter Plot</i> Data Curah Hujan Terhadap <i>Lag-Lag yang Signifikan</i>	38
Gambar 4.11 Arsitektur Jaringan RBFNN Jumlah Curah Hujan Kabupaten banyuwangi	41
Gambar 4.12 Data Aktual dan Peramalan dengan RBFNN	43
Gambar 4.13 Data Aktual (akt) dan Peramalan dengan ARIMA dan RBFNN.....	43

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

	Halaman
Tabel 2.1 Transformasi <i>Box-Cox</i>	8
Tabel 2.2 Bentuk ACF dan PACF untuk Model ARIMA	9
Tabel 3.1 Struktur Data.....	21
Tabel 4.1 Deskriptif Data Curah Hujan Kabupaten Banyuwangi Tahun 2011-2015.....	26
Tabel 4.2 Estimasi Parameter dari Model Sementara	33
Tabel 4.3 Statistik <i>Ljung-Box</i> Nilai Residual Model ARIMA	34
Tabel 4.4 Perbandingan Keباikan Model-Model ARIMA	36
Tabel 4.5 Nilai MSE Model Berdasarkan Banyak Kelompok yang Terbentuk	40
Tabel 4.6 Perbandingan Keباikan Model ARIMA dan RBFNN	44
Tabel 4.7 Nilai Ramalan Curah Hujan Kab. Banyuwangi Januari-Juni 2016	47

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data Curah Hujan Dasarian Kabupaten Banyuwangi.....	53
Lampiran 2 Nilai <i>Center</i> Pada K-Means Clustering	54
Lampiran 3 Nilai Standar Deviasi Pada K-Means Clustering ..	56
Lampiran 4 <i>Syntax</i> Penghitungan Bobot RBFNN Pada Matlab	58
Lampiran 5 <i>Syntax</i> Peramalan Data <i>Out Sample</i> Curah Hujan Pada R	59
Lampiran 6 <i>Syntax</i> Peramalan Data Curah Hujan Periode 181-198 Pada R.....	61
Lampiran 7 Perhitungan Kriteria Keباikan Model.....	63

(Halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kabupaten Banyuwangi, sebagai salah satu kabupaten produsen padi di Provinsi Jawa Timur, memiliki produktivitas sebesar 6,5 kw/ha hingga 6,7 kw/ha. Angka tersebut bahkan melampaui produktivitas padi nasional, yakni 5,9 kw/ha hingga 6,0k w/ha. Produksi padi di Banyuwangi sempat anjlok pada tahun 2011 akibat serangan hama, namun pada 2012 bangkit kembali. Atas keberhasilan Banyuwangi menghasilkan produksi padi yang sedemikian rupa, Presiden RI pada tahun 2012 memberikan penghargaan peningkatan produksi beras nasional (P2BN) kepada Bupati Banyuwangi.

Salah satu komponen lingkungan penentu keberhasilan usaha budidaya tanaman adalah iklim. Iklim ekstrim dapat berakibat buruk bagi pertumbuhan dan kualitas tanaman budidaya, khususnya tanaman semusim seperti tanaman pangan. Salah satu indikator iklim adalah curah hujan. Curah hujan didefinisikan sebagai jumlah air yang jatuh di permukaan tanah datar selama periode tertentu yang diukur dengan satuan tinggi (mm) di atas permukaan horizontal bila tidak terjadi evaporasi, *runoof*, dan infiltrasi. Curah hujan satu millimeter (1 mm), artinya dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi satu millimeter. Jumlah curah hujan sangat penting dalam menentukan hasil budidaya tanaman (Anwar, dkk, 2015). Peningkatan curah hujan di suatu daerah menimbulkan potensi banjir. Sebaliknya, bila terjadi penurunan curah hujan di suatu daerah, akan mengakibatkan kekeringan.

Mengingat pentingnya peranan curah hujan dalam penentuan musim tanam untuk mencapai hasil yang maksimal dalam rangka mencukupi kebutuhan pangan nasional, maka perlu dilakukan prediksi curah hujan di masa yang akan datang. Puslitbang Badan Meteorologi, Klimatologi, dan Geofisika

(BMKG) menjelaskan bahwa BMKG melakukan peramalan curah hujan dengan menggunakan metode *Ensemble Mean* dan *Ensemble Bayesian Model Averaging* (BMA). Hasil peramalan dengan metode tersebut divalidasi dengan diagram Taylor untuk melihat kebaikan hasil peramalan. Hasil diagram Taylor menunjukkan bahwa teknik *ensemble mean* dan *ensemble BMA* tidak selalu memberikan akurasi terbaik.

Metode ARIMA (*Autoregressive Integrated Moving Average*) merupakan salah satu metode pemodelan data deret berkala. Peramalan menggunakan model ARIMA mengasumsikan data yang digunakan berhubungan secara linier. Asumsi data berhubungan linier pada model ARIMA ditandai dengan nilai residual yang berdistribusi normal dan *whitenoise*. Pada kenyataannya, terjadi kondisi cuaca ekstrim di Banyuwangi. Pemodelan data yang mengandung nilai ekstrim dengan menggunakan model ARIMA menyebabkan nilai residual tidak berdistribusi normal dan *whitenoise*. Pendekatan linier kurang tepat digunakan untuk pemodelan data yang semacam ini. Oleh karena itu, diperlukan pendekatan lain yang menangkap pola nonlinier pada data curah hujan.

Jaringan saraf tiruan merupakan pemrosesan suatu informasi yang dibuat menyerupai kinerja sel-sel saraf biologi. Seperti jaringan saraf pada manusia, jaringan saraf tiruan dibentuk untuk memecahkan masalah melalui proses pembelajaran, yaitu identifikasi pola dan pengelompokan. Model jaringan saraf tiruan efektif digunakan pada model nonlinier. Jaringan saraf tiruan ditemukan sebelum adanya komputer, dan mulai dikembangkan pada tahun 1940-an. Metode jaringan saraf tirua pernah digunakan dalam memodelkan curah hujan di daerah sekitar aliran sungai Bengawan Solo oleh Fithriasari dkk (2013).

Radial Basis Function Neural Network (RBFNN) merupakan salah satu metode jaringan saraf tiruan yang dikembangkan pada tahun 1988. Model RBFNN terdiri dari lapisan *input*, lapisan *hidden*, dan lapisan *ouput*. Ciri khas RBFNN adalah memiliki satu lapisan tersembunyi dan

mengeluarkan nilai berupa persamaan linier pada lapisan *ouput*. Ciri khas ini menyebabkan proses kerja *RBFNN* lebih cepat dibandingkan jaringan saraf tiruan lainnya.

Perbandingan hasil analisis dengan metode ARIMA dan RBFNN telah dibahas dalam peramalan jumlah wisatawan di Indonesia (Haviluddin & Jawahir, 2015). Dikatakan bahwa hasil peramalan data wisatawan di Indonesia dengan RBFNN menghasilkan nilai *mean square error (MSE)* yang lebih kecil dibanding dengan metode ARIMA. Berdasarkan hasil tersebut, Haviluddin dan Jawahir merekomendasikan metode RBFNN sebagai salah satu metode alternatif untuk peramalan. Metode RBFNN juga pernah digunakan dalam peramalan curah hujan di Liuzhou, China (Wu, dkk, 2012). Wu dkk menggunakan RBFNN karena dapat memperkirakan fungsi kontinu dengan ketepatan yang diinginkan. Dalam peramalan harga saham, metode RBFNN juga pernah digunakan dengan alasan pergerakan harga saham merupakan pola nonlinier dan dipengaruhi oleh banyak faktor (Shen, dkk, 2010).

Dalam penelitian ini dinggunakan metode ARIMA dan *RBFNN* untuk meramalkan curah hujan di Kabupaten Banyuwangi. Penggunaan metode ARIMA digunakan untuk pendekatan linier terhadap data curah hujan dan RBFNN bertujuan untuk nonlinier pada data curah hujan. Hasil penelitian ini diharapkan dapat menjadi pendekatan yang lebih akurat untuk meramalkan curah hujan di Kabupaten Banyuwangi.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan, maka akan dilakukan pemodelan data curah hujan di Kabupaten Banyuwangi dengan model *Autoregressive Integrated Moving Average (ARIMA)* dan jaringan saraf tiruan dengan *Radial Basis Function (RBFNN)*. Pemodelan ini nantinya dapat digunakan untuk peramalan curah hujan di Kabupaten Banyuwangi.

1.3 Batasan Penelitian

Sebagai batasan dalam penelitian ini agar kajian lebih spesifik dan terarah adalah sebagai berikut:

1. Penentuan nilai *center* pada model *Radial Basis Function Neural Network (RBFNN)* menggunakan algoritma K-means.
2. Data yang digunakan dalam penelitian ini adalah data curah hujan di Kabupaten Banyuwangi pada Januari 2011- Desember 2015.
3. Data yang digunakan merupakan data pengukuran curah hujan dari Stasiun Meteorologi Kelas III Banyuwangi,

1.4 Tujuan Penelitian

Berangkat dari perumusan masalah yang telah dijelaskan sebelumnya, tujuan dari penelitian ini adalah:

1. Memodelkan data curah hujan di Kabupaten Banyuwangi dengan model ARIMA dan RBFNN.
2. Membandingkan hasil ramalan dengan menggunakan model ARIMA dan RBFNN.

1.5 Manfaat Penelitian

Hasil penelitian ini diharapkan dapat membantu BMKG mendapatkan model yang lebih baik untuk peramalan curah hujan di Kabupaten Banyuwangi. Adanya informasi peramalan curah hujan dari penelitian ini diharapkan dapat dijadikan pertimbangan dalam perencanaan kalender tanam agar mendapatkan hasil panen yang lebih baik.

BAB II

TINJAUAN PUSTAKA

2.1 Peramalan

Peramalan merupakan teknik untuk memprediksi keadaan di masa yang akan datang berdasarkan kondisi di masa lalu maupun kondisi saat ini. Berdasarkan periodenya, peramalan dibagi menjadi 3 bentuk (Montgomery, dkk, 2008):

1. Jangka Pendek (*Short Term*)

Peramalan jangka pendek meliputi kurun waktu mulai dari hari, minggu, sampai bulan. Data historis sangat relevan dalam peramalan ini, karena jangka waktu peramalan sangat singkat. Contoh peramalan jangka pendek adalah peramalan penjualan produk satu bulan ke depan.

2. Jangka Menengah (*Medium Term*)

Peramalan jangka menengah meliputi kurun waktu mulai dari satu musim (triwulan, kuartal, atau lainnya) sampai dua tahun ke depan. Dalam peramalan jangka menengah, data historis masih dianggap relevan. Salah satu contoh peramalan jangka menengah adalah peramalan anggaran produksi.

3. Jangka Panjang (*Long Term*)

Data di masa lalu kurang relevan dalam peramalan jangka panjang. Hal ini disebabkan oleh peramalan jangka panjang meliputi kurun waktu dua tahun ke depan atau lebih. Dalam peramalan harga saham, peramalan jangka panjang biasanya menggunakan analisis fundamental dan intuisi.

2.2 Model Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA merupakan penggabungan antara model *Autoregressive* (AR) dan *Moving Average* (MA) serta proses *differencing* (orde d untuk data non musiman, orde D untuk data musiman) terhadap data *time series*.

2.2.1 Model ARIMA Non Musiman

Secara umum, model ARIMA (p, d, q) dapat ditulis sebagai berikut (Wei, 2006) :

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)a_t, \quad (2.1)$$

dengan :

(p, d, q) : orde AR (p) , orde *differencing* (d) , orde MA (q) untuk data non musiman.

$\phi_p(B)$: komponen AR non musiman dengan orde (p) , penjabarannya sebagai berikut:
 $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$

$\theta_q(B)$: komponen MA non musiman dengan orde (q) , penjabarannya sebagai berikut:
 $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$

$(1 - B)^d$: *differencing* non musiman dengan orde (d)

Z_t : besarnya pengamatan (kejadian) pada waktu ke t

a_t : nilai residual pada saat t

2.2.2 Model ARIMA Musiman

Secara umum, model ARIMA (P, D, Q) dapat ditulis sebagai berikut (Wei, 2006) :

$$\Phi_P(B^S)(1 - B)^D Z_t = \Theta_Q(B^S)a_t, \quad (2.2)$$

dengan :

$(P, D, Q)^S$: orde AR (P) , orde *differencing* (D) , orde MA (Q) untuk data musiman (S) .

$\Phi_P(B)$: komponen AR musiman dengan orde (P) dengan penjabaran sebagai berikut:
 $\Phi_P(B^S) = (1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS})$

$\Theta_Q(B)$: komponen MA musiman dengan orde (Q) dengan penjabaran sebagai berikut:
 $\Theta_Q(B^S) = (1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS})$

$(1 - B)^D$: *differencing* musiman dengan orde (D)

Z_t : besarnya pengamatan (kejadian) pada waktu ke t

a_t : nilai residual pada saat t

2.3 Identifikasi Model ARIMA

Dalam *time series*, langkah yang paling penting adalah mengidentifikasi dan membentuk model dari data yang diteliti. Namun sebelum mengidentifikasi model, data yang tersedia harus memenuhi syarat kestasioneran, baik dalam *varians* maupun dalam *mean*. Artinya bahwa mean dan varians data adalah konstan, tidak dipengaruhi oleh waktu t . Identifikasi model ARIMA dapat dilakukan dengan melihat plot ACF dan PACF.

2.3.1 Stasioner

Langkah pertama yang dilakukan dalam identifikasi model adalah membuat plot *time series*, menghitung ACF dan PACF untuk mengidentifikasi kestasioneran secara *mean* maupun *varians*. Jika *time series plot* berfluktuasi di sekitar garis yang sejajar sumbu waktu t maka dapat dikatakan bahwa deret waktu sudah stasioner dalam *mean*, jika kondisi stasioner dalam *mean* tidak terpenuhi maka perlu dilakukan *differencing* terhadap data. Jika *time series plot* menunjukkan bahwa data sudah stasioner dalam *mean*, belum tentu data sudah stasioner terhadap *varians* (Wei, 2006). Suatu data telah memenuhi syarat stasioner dalam *varians* jika nilai *rounded value* (λ) sudah bernilai 1, atau nilai batas *lower* dan *upper*-nya telah melewati 1. Jika syarat stasioner dalam *varians* belum terpenuhi maka perlu dilakukan transformasi. Transformasi yang diperkenalkan dalam buku Wei (2006) adalah transformasi *Box-Cox*, dengan rumus:

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.3)$$

Untuk kasus-kasus dengan nilai lambda tertentu bentuk transformasi ditampilkan pada tabel berikut (Wei, 2006):

Tabel 2.1 Transformasi *Box-Cox*

Nilai λ (Lamda)	Transformasi
-1	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0	$\text{Ln } Z_t$
0,5	$\sqrt{Z_t}$
1	Z_t

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

ACF merupakan suatu koefisien yang menunjukkan hubungan linier pada data *time series* antara Z_t dengan Z_{t-k} . Dalam suatu proses stasioner $\{Z_t\}$ diketahui bahwa nilai $E(Z_t) = E(Z_{t+k}) = \mu$ dan nilai $\text{var}(Z_t) = E(Z_t - \mu)^2 = E(Z_{t+k} - \mu)^2 = \sigma^2$, dimana nilai *mean* dan *varians* tersebut konstan. Persamaan dari kovarians antara $\{Z_t\}$ dengan $\{Z_{t-k}\}$ seperti berikut :

$$\gamma_k = \text{Cov}(Z_t, Z_{t-k}) = E(Z_t - \mu)(Z_{t-k} - \mu), \quad (2.4)$$

dan korelasi antara $\{Z_t\}$ dengan $\{Z_{t-k}\}$ adalah sebagai berikut (Wei, 2006):

$$\rho_k = \frac{\text{Cov}(Z_t, Z_{t-k})}{\sqrt{\text{Var}(Z_t)}\sqrt{\text{Var}(Z_{t-k})}} = \frac{\gamma_k}{\gamma_0}, \quad (2.5)$$

γ_k merupakan fungsi autokovarians dan ρ_k merupakan fungsi autokorelasi antara $\{Z_t\}$ dengan $\{Z_{t-k}\}$ dari proses yang sama dan hanya terpisah oleh lag waktu ke- k .

PACF berfungsi untuk mengukur tingkat keeratan hubungan (korelasi) antara pasangan data Z_t dan Z_{t-k} setelah pengaruh variabel $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$ dihilangkan. Korelasi tersebut adalah sebagai berikut :

$$\text{Corr}(Z_t, Z_{t-k} | Z_{t-1}, \dots, Z_{t-k+1}). \quad (2.6)$$

Dengan menganggap proses stasioner $\{Z_t\}$, diasumsikan bahwa $E(Z_t) = 0$. Jika \hat{Z}_{t-k} taksiran linier terbaik dari Z_{t-k} , maka (Wei, 2006):

$$\hat{Z}_{t-k} = \alpha_1 Z_{t-k-1} + \alpha_2 Z_{t-k-2} + \dots + \alpha_k Z_1, \quad (2.7)$$

dimana $\alpha_i (1 \leq i \leq k)$ merupakan koefisien regresi linier yang diperoleh dari :

$$E(Z_{t-k} - \hat{Z}_{t-k})^2 = E(Z_{t-k} - \alpha_1 Z_{t-k-1} - \dots - \alpha_k Z_1)^2 \quad (2.8)$$

Dengan cara yang sama,

$$\hat{Z}_t = \beta_1 Z_{t-1} + \beta_2 Z_{t-2} + \dots + \beta_k Z_{t-k}, \quad (2.9)$$

dimana, $\beta_i (1 \leq i \leq k-1)$ merupakan koefisien regresi linier yang diperoleh dari:

$$E(Z_t - \hat{Z}_t)^2 = E(Z_t - \beta_1 Z_{t-1} - \dots - \beta_k Z_{t-k})^2. \quad (2.10)$$

Fungsi parsial autokorelasi antara Z_t dan Z_{t-k} bernilai sama dengan autokorelasi antara $Z_t - \hat{Z}_t$ dan $Z_{t-k} - \hat{Z}_{t-k}$, sehingga fungsi autokorelasi parsial dapat dihitung dengan rumus sebagai berikut (Wei, 2006) :

$$P_k = \frac{\text{Cov}[(Z_t - \hat{Z}_t), (Z_{t-k} - \hat{Z}_{t-k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)} \sqrt{\text{Var}(Z_{t-k} - \hat{Z}_{t-k})}}. \quad (2.11)$$

dimana \hat{Z}_t dijelaskan pada persamaan (2.9) dan \hat{Z}_{t-k} dijelaskan pada persamaan (2.7).

Bentuk-bentuk plot ACF dan PACF dari model ARIMA ditampilkan pada tabel berikut (Wei, 2006) :

Tabel 2.2 Bentuk ACF dan PACF untuk model ARIMA		
Model	ACF	PACF
AR (p)	Turun cepat (<i>dies down</i>)	<i>Cuts off after lag p</i>
MA (q)	<i>Cuts off after lag p</i>	Turun cepat (<i>dies down</i>)
AR (p) atau MA(q)	<i>Cuts off after lag p</i>	<i>Cuts off after lag p</i>

ARMA (p,q)	Turun cepat (<i>dies</i> <i>down</i>) <i>afterlag</i> (q-p)	Turun cepat (<i>dies</i> <i>down</i>) <i>afterlag</i> (q - p)
-------------------	--	--

2.3.3 Estimasi Parameter

Salah satu metode estimasi parameter adalah metode *Least Square Estimation*. Metode *Least Square Estimation* merupakan suatu metode mencari nilai parameter yang dilakukan dengan cara yang meminimumkan jumlah kuadrat residual (selisih antara nilai aktual dengan ramalan). Untuk model AR(1) dinyatakan dalam rumus berikut (Cryer & Chan, 2008) :

$$S_c(\phi_1, \mu) = \sum_{t=2}^n [(Z_t - \mu) - \phi_1(Z_{t-1} - \mu)]^2. \quad (2.12)$$

Berdasarkan prinsip dari metode *Least Square*, penaksiran ϕ_1 dan μ dilakukan dengan meminimumkan $S_c(\phi_1, \mu)$. Hal ini dilakukan dengan menurunkan $S_c(\phi_1, \mu)$ terhadap μ dan ϕ_1 kemudian disamadengankan nol. Meminimumkan $S_c(\phi_1, \mu)$ terhadap μ menghasilkan rumus berikut :

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=2}^n 2[(Z_t - \mu) - \phi_1(Z_{t-1} - \mu)](-1 + \phi_1) = 0 \quad (2.13)$$

dengan cara yang sederhana,

$$\mu = \frac{\sum_{t=2}^n Z_t - \phi_1 \sum_{t=2}^n Z_{t-1}}{(n-1)(1-\phi_1)}. \quad (2.14)$$

Untuk n besar,

$$\frac{1}{n-1} \sum_{t=2}^n Z_t \approx \frac{1}{n-1} \sum_{t=2}^n Z_{t-1} \approx \bar{Z}, \quad (2.15)$$

sehingga, diperoleh nilai taksiran parameter untuk μ dari model AR(1) sebagai persamaan berikut :

$$\hat{\mu} = \frac{\bar{Z} - \phi_1 \bar{Z}}{1 - \phi_1} = \frac{\bar{Z}(1 - \phi_1)}{1 - \phi_1} = \bar{Z} \quad (2.16)$$

Dengan cara yang sama operasi turunan terhadap ϕ_1 yaitu seperti rumus berikut (Cryer & Chan, 2008) :

$$\frac{\partial S_c}{\partial \phi} = \sum_{t=2}^n 2[(Z_t - \bar{Z}) - \phi_1(Z_{t-1} - \bar{Z})](Z_{t-1} - \bar{Z}) = 0, \quad (2.17)$$

sehingga diperoleh nilai taksiran sebagai berikut :

$$\hat{\phi}_1 = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \quad (2.18)$$

2.3.4 Pengujian Signifikansi Parameter

Pengujian signifikansi parameter dilakukan untuk mengetahui apakah hasil penaksiran parameter model ARIMA signifikan atau tidak, sehingga dapat diketahui apakah tiap variabel yang digunakan berpengaruh pada Z_t . Pengujian hipotesis dilakukan dengan menggunakan uji t . Misalkan yang diuji adalah parameter MA yaitu θ , maka hipotesis yang diuji adalah sebagai berikut :

H_0 : $\theta_i = 0$ (parameter tidak signifikan terhadap model) untuk
 $i = 1, 2, \dots, q$

H_1 : $\theta_i \neq 0$ (parameter sudah signifikan terhadap model)

Statistik uji (Bowerman & O'Connell, 1993):

$$t_{hitung} = \frac{\hat{\theta}_i}{S_{\hat{\theta}_i}}, \quad (2.19)$$

dengan $\hat{\theta}_i$ merupakan nilai estimasi dari θ_i dan $S_{\hat{\theta}_i}$ adalah standar error dari nilai taksiran $\hat{\theta}_i$. Tolak H_0 jika $|t_{hitung}| > t_{\alpha/2, df=n-p}$ dengan p adalah banyaknya parameter, atau tolak H_0 jika $P_{value} < \alpha$, dengan α adalah taraf signifikansi.

2.3.5 Validasi Model dan Pemilihan Model Terbaik

Model ARIMA mengasumsikan nilai residual berdistribusi normal dan *white noise* (Wei, 2006). Residual (a_t) dikatakan *white noise* jika memenuhi dua sifat, yaitu identik (memiliki varians konstan) dan independen (nilai residual tidak saling berkorelasi) dengan rata-rata nol. Uji asumsi *white noise* dapat dilakukan dengan uji *Ljung-Box*. Hipotesis dalam pengujian ini adalah sebagai berikut:

- H_0 : $\rho_1 = \rho_2 = \dots = \rho_K = 0$ (Residual *white noise*)
 H_1 : minimal ada satu $\rho_j \neq 0$, (Residual tidak *white noise*)
 $j = 1, 2, \dots, K$.

Statistik uji:

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k}, \quad (2.20)$$

dengan: n = banyak pengamatan,
 $\hat{\rho}_k^2$ = ACF residual kuadrat pada lag ke k
 K = maksimum lag

Keputusan H_0 ditolak jika nilai $Q > \chi^2_{(1-\alpha), df=K-p-q}$, dengan p dan q merupakan orde AR dan MA. Keputusan juga dapat diambil berdasarkan nilai *p-value*. Jika *p-value* $> \alpha$ maka residual memenuhi asumsi *white noise*.

Pengujian nilai residual berdistribusi normal $(0, \sigma^2)$ dapat dilakukan dengan uji *Kolmogorov-Smirnov*. Hipotesis yang digunakan adalah sebagai berikut:

- H_0 : $F(a) = F_0(a)$ (Residual berdistribusi normal)
 H_1 : $F(a) \neq F_0(a)$ (Residual tidak berdistribusi normal)

Statistik uji:

$$D = \text{Sup}|S(a) - F_0(a)|, \quad (2.21)$$

dengan,

$S(a)$ = fungsi peluang kumulatif yang dihitung dari data sampel.

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

Sup = nilai supremum untuk semua a dari $|S(a) - F_0(a)|$

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

Pemilihan model terbaik dalam penelitian ini dilakukan dengan membandingkan nilai *Mean Square Error* (MSE). Nilai MSE digunakan untuk mengukur ketepatan nilai dugaan model yang dinyatakan dalam rata-rata kuadrat dari kesalahan. Perhitungan nilai MSE dilakukan dengan rumus sebagai berikut (Wei, 2006):

$$MSE = \frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2 \quad (2.22)$$

Selain dari perbandingan nilai MSE, pemilihan model terbaik dapat juga dilakukan dengan perbandingan nilai *Mean Absolute Error* (MAE) dari setiap model. Nilai MAE lebih kecil menandakan bahwa model tersebut lebih baik. Perhitungan nilai MAE dilakukan dengan rumus sebagai berikut (Wei, 2006):

$$MAE = \frac{1}{n} \sum_{t=1}^n |Z_t - \hat{Z}_t| \quad (2.23)$$

2.4 Uji Linieritas

Uji linieritas dapat dilakukan dengan Uji Terasvirta. Uji Terasvirta merupakan pengujian linieritas tipe LM (*Lagrange Multiplier*). Prosedur pengujian linieritas dengan Uji Terasvirta adalah sebagai berikut :

1. Regresikan Z_t pada 1 dan Z_{t-k} , $k=1,2, \dots, p$. Sehingga diperoleh model linear

$$Z_t = f_t + \hat{\epsilon}_t, \quad (2.24)$$

dimana $f_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}$,

kemudian menghitung jumlah kuadrat nilai residual yaitu $SSR_0 = \sum \hat{\epsilon}_t^2$.

2. Meregresikan $\hat{\epsilon}_t$ pada 1, Z_{t-1} , Z_{t-2} , ..., Z_{t-p} dan m prediktor tambahan yang merupakan hasil pendekatan ekspansi Taylor, dan kemudian menghitung jumlah kuadrat nilai residual $SSR_1 = \sum \hat{v}_t^2$.
3. Menghitung nilai statistik uji sebagai berikut:

$$F_{hit} = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(n-p-1-m)}. \quad (2.25)$$

dengan n adalah jumlah pengamatan. Hipotesisi yang digunakan adalah sebagai berikut:

H_0 : Model linier

H_0 : Model nonlinier

Statistik uji F mengikuti distribusi $F_{(\alpha, m, (n-p-1-m))}$. H_0 ditolak jika nilai $F_{\text{hit}} > F_{(\alpha, m, (n-p-1-m))}$ atau nilai p-value dari statistik uji F kurang dari α .

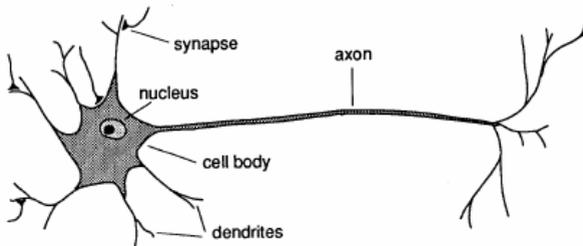
2.5 Jaringan Saraf

2.5.1 Jaringan Saraf Biologi

Otak manusia terdiri dari 100 miliar sel saraf yang saling berhubungan, yang disebut *neuron*. Masing-masing *neuron* terhubung dengan lain, dengan sinapsis yang menghubungkannya. Setiap sel *neuron* memiliki satu inti sel. Inti sel ini bertugas melakukan pemrosesan informasi. *Neuron* biologi merupakan sistem yang “*fault tolerant*” dalam dua hal. Pertama, manusia dapat mengenali sinyal *input* yang berbeda dengan yang telah dikenali sebelumnya. Kedua, otak manusia dapat tetap bekerja meskipun beberapa *neuron*nya tidak bekerja dengan baik. Jika satu *neuron* rusak, maka *neuron* lain dapat dilatih untuk menggantikan fungsi sel yang rusak.

Komponen-komponen utama dari sebuah *neuron* dikelompokkan menjadi tiga bagian, yaitu (Fausett, 1994):

1. *Dendrite*, bertugas menerima informasi.
2. Badan sel (*soma*), bertugas mengelola informasi, dan
3. *Akson/axon (neurit)*, bertugas mengirim impuls-impuls ke sel saraf lainnya.



Gambar 2.1 Jaringan Saraf Biologis

Secara umum, cara kerja sebuah *neuron* terhadap suatu informasi adalah berawal dari *dendrite* yang bertugas menerima informasi. Informasi ini dilewatkan melalui *sinapsis* yang pada

perjalanan biologisnya terjadi proses kimiawi. Proses kimiawi tersebut, pada jaringan saraf tiruan, disebut bobot. Informasi yang diterima diolah oleh *soma*. Untuk mengirim informasi ke sel lain, informasi dilewatkan melalui *akson*. Selanjutnya informasi diterima oleh *dendrite neuron* lain, dan terjadi hal yang sama dengan *neuron* sebelumnya.

2.5.2 Jaringan Saraf Tiruan

Jaringan saraf tiruan atau *Neural Network (NN)* adalah sistem pemrosesan informasi yang memiliki karakteristik mirip jaringan saraf biologi. NN dibentuk sebagai generalisasi model matematika dari jaringan saraf biologi, dengan asumsi sebagai berikut (Fausett, 1994):

1. pemrosesan informasi terjadi pada banyak elemen sederhana (*neuron*),
2. sinyal dikirimkan di antara *neuron-neuron* melalui penghubung-penghubung,
3. penghubung antar *neuron* memiliki bobot yang akan memperkuat atau memperlemah sinyal, dan
4. untuk menentukan *ouput*, setiap *neuron* menggunakan fungsi aktivasi yang dikenakan pada jumlahan *input* yang diterima.

Unsur-unsur dalam *NN* bekerja secara paralel. Jaringan ini dapat ditentukan dengan hubungan antar unsur-unsurnya untuk mencapai target tertentu. *NN* dapat diaplikasikan di berbagai bidang terutama pada analisis kompleks yang memiliki masalah nonlinier.

2.5.3 Kerangka Jaringan Saraf Tiruan

Pada jaringan saraf tiruan (*NN*), *neuron-neuron* akan dikumpulkan dalam lapisan-lapisan (*layer*) yang disebut *neuron layer*. Pada umumnya, *NN* mempunyai tiga macam lapisan, yaitu:

1. Lapisan *Input (Input Layer)*

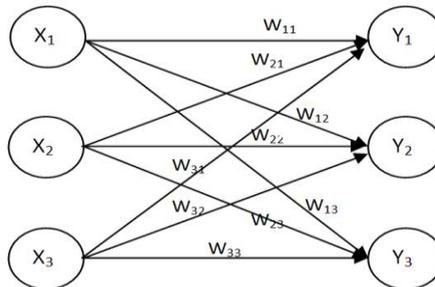
- Node-node dalam lapisan *input* disebut *neuron-neuron input*. *Neuron-neuron input* menerima *input* berupa gambaran suatu permasalahan dari luar.
2. Lapisan Tersembunyi (*Hidden layer*)
Node-node di lapisan tersembunyi disebut *neuron-neuron tersembunyi*.
 3. Lapisan *Ouput* (*Ouput Layer*)
Node-node di lapisan *ouput* disebut *neuron-neuron ouput*. Keluaran dari lapisan ini merupakan hasil dari *neural network* terhadap suatu permasalahan.

2.5.4 Arsitektur Jaringan Saraf Tiruan

Pengaturan *neuron* dalam setiap lapisan dan pola hubungan antar lapisan disebut arsitektur jaringan saraf. Arsitektur *neural network* diklasifikasikan menjadi 3, yaitu (Fausett, 1994) :

1. Jaringan Lapisan Tunggal (*Single Layer Net*)

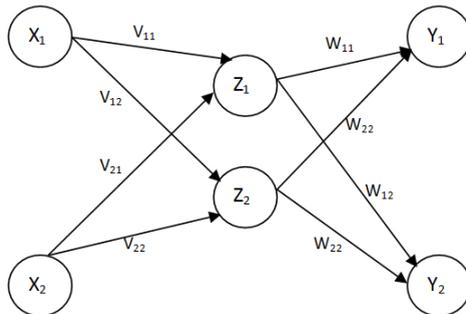
Jaringan dengan lapisan tunggal memiliki satu lapisan dengan bobot-bobot terhubung. Jaringan ini hanya menerima *input* kemudian secara langsung akan mengolahnnya menjadi *ouput* tanpa harus melalui lapisan lain (lapisan tersembunyi). Dengan kata lain, ciri-ciri dari arsitektur jasingan saraf lapisan tunggal adalah hanya terdiri dari satu lapisan *input* dan satu lapisan *ouput*. Pada jaringan lapisan tunggal hanya terdapat satu jenis pembobot. Contoh arsitektur jaringan dengan lapisan tunggal dapat dilihat pada Gambar 2.2.



Gambar 2.2 Arsitektur Jaringan Lapis Tunggal

2. Jaringan Banyak Lapisan (*Multilayer Net*)

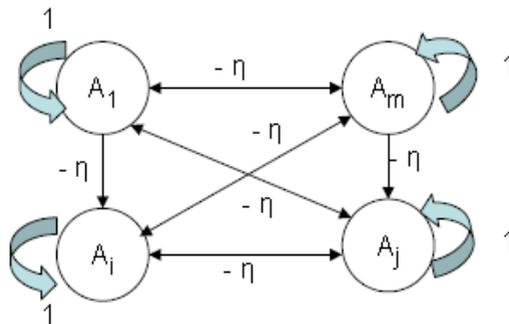
Jaringan dengan banyak lapisan memiliki satu atau lebih lapisan yang berada di antara lapisan *input* dan lapisan *output* (terdapat satu atau lebih lapisan tersembunyi). Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih sulit dibanding dengan jaringan dengan lapisan tunggal. Contoh arsitektur jaringan banyak lapisan dapat dilihat pada Gambar 2.3.



Gambar 2.3 Arsitektur Jaringan Banyak Lapisan

3. Jaringan Lapisan Kompetitif (*Competitive Layer Net*)

Pada jaringan lapisan kompetitif, neuron-neuron dapat saling dihubungkan. Contoh arsitektur jaringan lapisan kompetitif dapat dilihat pada Gambar 2.4.



Gambar 2.4 Arsitektur Jaringan Lapisan Kompetitif

2.5.5 Metode Pembelajaran dan Pelatihan

Salah satu bagian terpenting dari konsep jaringan saraf adalah terjadinya proses pembelajaran. Tujuan utama dari proses pembelajaran adalah melakukan pengaturan terhadap bobot-bobot yang ada pada jaringan saraf, sehingga diperoleh bobot akhir yang tepat sesuai pola data yang dilatih. Pada dasarnya terdapat 2 metode pembelajaran, yaitu metode pembelajaran terawasi (*supervised learning*) dan metode pembelajaran tidak terawasi (*unsupervised learning*) (Fausett, 1994).

1. Pembelajaran Terawasi (*supervised learning*)

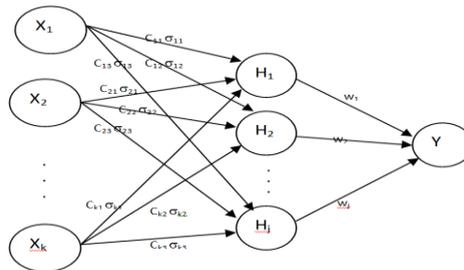
Pada proses pembelajaran ini, satu *input* yang telah diberikan pada satu *neuron* di lapisan *input* akan dijalankan di sepanjang jaringan saraf sampai ke *neuron* pada lapisan *ouput*. Hasil *ouput* yang diperoleh kemudian dicocokkan dengan target. Jika *error* yang didapat cukup besar, akan dilakukan pembelajaran yang lebih banyak lagi.

2. Pembelajaran Tidak Terawasi (*unsupervised learning*)

Pada proses pembelajaran ini, nilai bobot disusun dalam suatu interval atau range tertentu, tergantung pada *input* yang diberikan. Pembelajaran ini bertujuan mengelompokkan unit-unit yang hampir sama dalam satu area tertentu.

2.5.6 Jaringan Saraf Tiruan Radial Basis Function (RBF)

Jaringan saraf tiruan RBF memiliki 3 *layer*, yaitu *input layer*, *hidden layer*, dan *ouput layer*. Arsitektur jaringan RBFNN dijelaskan pada Gambar 2.5.



Gambar 2.5 Arsitektur RBFNN

Output dirumuskan sebagai berikut:

$$\hat{y} = \sum_{j=1}^m w_j h_j(x) \quad (2.26)$$

Fungsi aktivasi dengan RBF (Gaussian) dinyatakan sebagai berikut:

$$h_j(x) = \exp\left(-\sum_{i=1}^k \left(\frac{\|x_i - c_j\|^2}{\sigma_j^2}\right)\right) \quad (2.27)$$

Dimana:

- c_j = vektor *Center* pada node ke- j
- σ_j = standar deviasi pada node ke- j .
- x = vektor *input*

Selanjutnya, penentuan bobot dapat dilakukan dengan metode *least square*. Tiap-tiap fungsi *neuron* pada lapisan *input* mempunyai satu nilai *center* dan satu nilai standar deviasi tertentu. Setiap *neuron* pada lapisan tersembunyi memiliki satu nilai bobot.

Penentuan *center* dan standar deviasi dilakukan dengan algoritma K-means. Proses ini berlangsung pada node-node pada lapisan *input* dengan lapisan tersembunyi. Algoritma K-Means disusun atas dasar ide pengelompokan objek-objek yang terdekat. Pada awalnya ditentukan banyak cluster yang akan dibentuk (g) dari data yang berukuran n dan terdiri dari k variabel. Sembarang obyek atau elemen pertama dalam cluster dapat dipilih untuk dijadikan sebagai titik tengah (*centroid point*) cluster. Selanjutnya dilakukan pengulangan langkah-langkah berikut sampai terjadi kestabilan atau tidak ada obyek yang dapat dipindahkan (Rencher, 2002):

1. Menentukan koordinat titik tengah (*centroid*) setiap cluster,
2. Menentukan jarak setiap obyek terhadap koordinat titik tengah. Misalkan terdapat sebanyak k variabel *input* dan sebanyak n pasangan data, sehingga terbentuk matrik *input* $X_{n \times k}$. Cluster yang akan dibentuk adalah sebanyak

g , sehingga terdapat matrik titik pusat $\mathbf{C}_{g \times k}$. Perhitungan jarak setiap pasang data terhadap titik pusat dihitung dengan rumus berikut:

$$d(\mathbf{x}_l, \mathbf{c}_j) = \sqrt{\sum_{i=1}^k (\mathbf{x}_{li} - \mathbf{c}_{ji})^2}, \quad (2.28)$$

dimana:

x = vektor input

c = nilai *center*

i = indeks variabel (1,2,...,k)

j = indeks kelompok (1,2,...,g)

l = indeks pasangan data (1,2,...,n)

3. Mengelompokkan obyek-obyek tersebut berdasarkan pada jarak minimumnya ke titik pusat.

Ketika kelompok yang stabil sudah terbentuk, didapat nilai *centroid* dari setiap kelompok yang dan nilai standar deviasi yang kemudian dijadikan pembobot pada jaringan RBFNN. Matrik standar deviasi ($\mathbf{\Sigma}_{g \times k}$) dihitung dari kelompok yang sudah terbentuk dari metode K-means.

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data curah hujan harian di Kabupaten Banyuwangi yang diambil dari Stasiun Meteorologi Kelas III Banyuwangi.

3.2 Variabel Penelitian

Variabel dalam penelitian ini adalah jumlah curah hujan dasarian di Kabupaten Banyuwangi, yang merupakan penjumlahan dari jumlah curah hujan harian dalam satuam millimeter (mm). Struktur organisasi data yang akan digunakan seperti pada Tabel 3.1.

Tabel 3.1 Struktur Data

Tahun	Curah Hujan
2011	Z_1
	Z_2
	\vdots
	Z_{36}
\vdots	\vdots
2015	Z_{145}
	Z_{146}
	\vdots
	Z_{180}

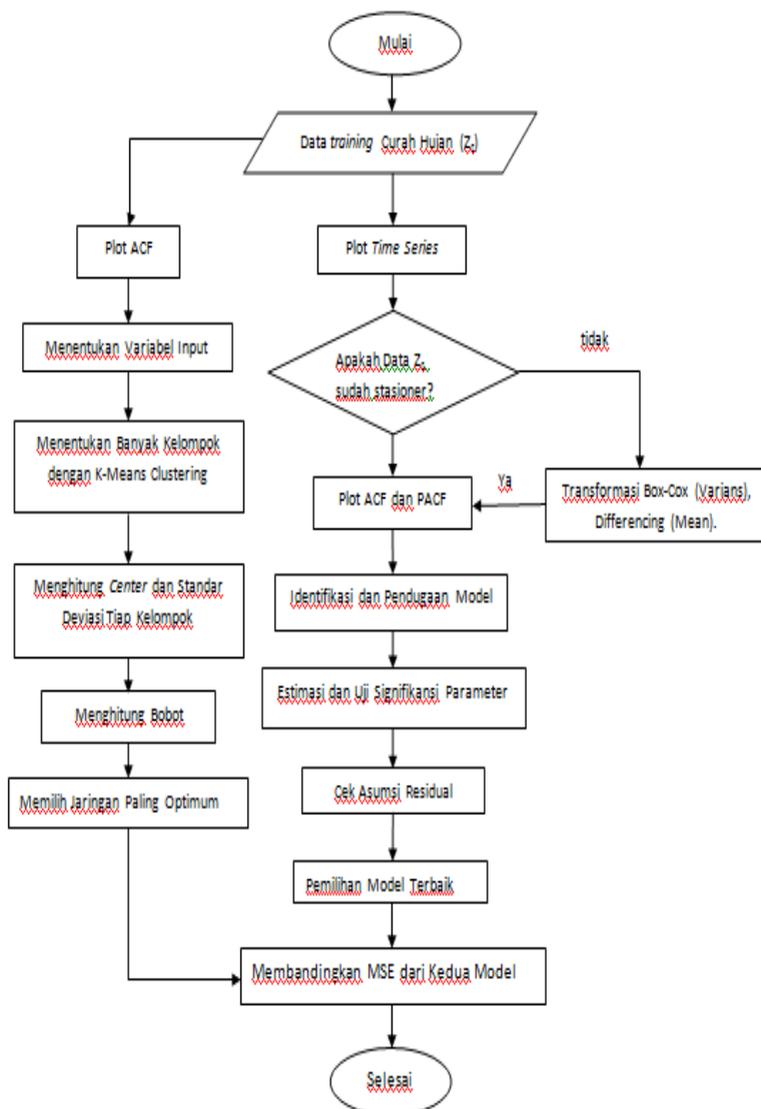
3.3 Metode Analisis Data

Langkah-langkah analisis data yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. *Preprocessing* data, yaitu imputasi terhadap *missing data*, dan penjumlahan data harian menjadi data dasarian.
2. Membagi data menjadi dua, yaitu data *in sample* (periode Januari 2011-Desember 2014) dan data *out sample* (Januari 2015- Desember 2015).
3. Memeriksa stasioneritas data terhadap varians dan mean dan mengatasi ketidakstasioneran data dengan transformasi (jika tidak stasioner terhadap varians) dan *differencing* (jika tidak stasioner terhadap mean).
4. Membuat model ARIMA dengan melihat plot ACF dan PACF data yang sudah stasioner terhadap varians dan mean.
5. Memeriksa residual *white noise* dan berdistribusi normal.
6. Menentukan model ARIMA terbaik berdasarkan nilai MSE pada data *out sample*.
7. Menentukan variabel input dengan melihat plot fungsi autokorelasi (ACF) dari data *training*. Variabel input ditentukan oleh *lag-lag* yang nilai ACF-nya signifikan.
8. Menentukan nilai pusat dengan menggunakan metode Klaster K-means dan menghitung nilai varians dari hasil pengelompokan.
9. Menentukan jaringan yang optimum. Jaringan yang optimum adalah jaringan dengan nilai MSE terkecil dari data *testing*.
10. Membandingkan nilai MSE dari hasil pemodelan dengan ARIMA dan RBFNN.

3.4 Diagram Alir

Analisis yang akan dilakukan dalam penelitian ini dipaparkan dalam diagram alir pada Gambar 3.1.



Gambar 3.1 Diagram Alir Penelitian Model ARIMA dan RBFNN

(Halaman ini sengaja dikosongkan)

BAB IV

ANALISIS DAN PEMBAHASAN

Bab ini membahas hasil penelitian terhadap data curah hujan di Kabupaten Banyuwangi. Data curah hujan dimodelkan dengan model ARIMA dan model *Radial Basis Function Neural Network* (RBFNN). Penggunaan model RBFNN diharapkan mampu menangkap pola non linier yang tidak dapat ditangkap oleh model ARIMA. Data yang digunakan pada awalnya merupakan data harian, sehingga perlu dilakukan *pre-processing* data. *Pre-processing* data yang dilakukan pada penelitian ini meliputi imputasi terhadap data kosong, penjumlahan data harian menjadi data dasarian dan transformasi data untuk mengatasi data yang bernilai nol.

4.1 Deskriptif Data Curah Hujan Kabupaten Banyuwangi

Data awal yang digunakan merupakan data harian yang kemudian diubah bentuknya menjadi data dasarian. Data dasarian pertama dalam satu bulan merupakan penjumlahan data curah hujan pada 10 hari pertama pada bulan tersebut. Data dasarian kedua merupakan penjumlahan 10 hari kedua pada bulan yang sama. Data dasarian ketiga merupakan penjumlahan data pada sisa hari pada bulan yang sama.

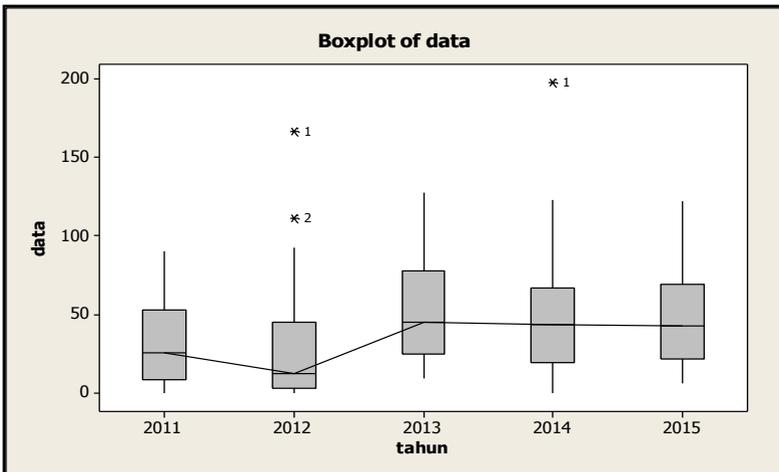
Pada data asli terdapat nilai-nilai yang hilang dikarenakan tidak dilakukan pengukuran, sehingga diperlukan imputasi data. Metode imputasi yang digunakan adalah mengisi nilai yang hilang dengan nilai rata-rata pada tanggal yang sama selama tahun 2000-2010. Adapun yang melatarbelakangi pemilihan metode imputasi ini adalah adanya kecenderungan terdapat pola musim setiap tahun. Pola musim yang dimaksudkan adalah curah hujan pada bulan tertentu pada setiap tahun biasanya tidak berbeda jauh dengan bulan yang sama pada tahun sebelumnya.

Deskriptif data curah hujan di Kabupaten Banyuwangi dijelaskan dalam Tabel 4.1.

Tabel 4.1 Deskriptif Data Curah Hujan Kabupaten Banyuwangi Tahun 2011-2015

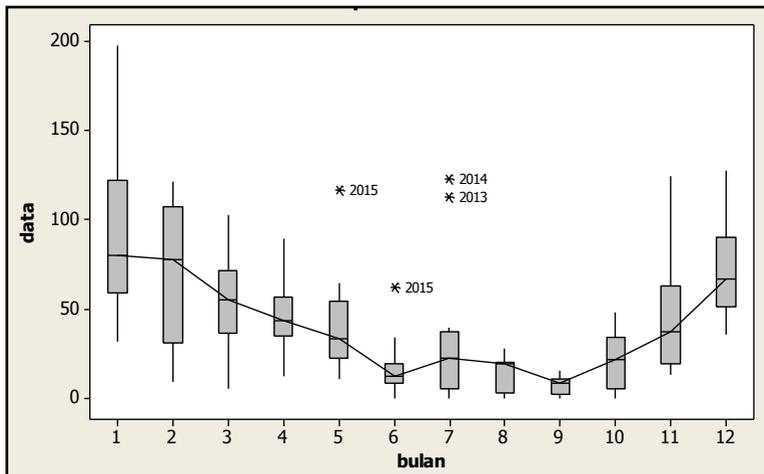
Tahun	Mean	St.Dev	Minimum	Maximum	Median
2011	31,39	28,41	0,00	90,00	25,14
2012	28,64	36,84	0,00	166,00	12,50
2013	53,11	35,11	9,20	127,07	45,12
2014	49,92	41,10	0,00	197,16	43,40
2015	49,32	33,83	6,30	122,11	42,51

Diketahui bahwa jumlah curah hujan dasarian tertinggi selama tahun 2011-2015 terjadi tahun 2014. Sebaran data curah hujan Kabupaten Banyuwangi digambarkan dalam *boxplot* pada Gambar 4.1.



Gambar 4.1 Sebaran Data Curah Hujan Per Tahun Kab. Banyuwangi Tahun 2011- 2015

Berdasarkan *boxplot* pada Gambar 4.1, dapat dilihat bahwa pada tahun 2012 terjadi penurunan nilai median curah hujan di Kabupaten Banyuwangi. Penurunan intensitas curah hujan pada tahun 2012 sempat mengakibatkan lahan sawah di Kabupaten Banyuwangi terancam kekeringan. Pada tahun 2013 terjadi peningkatan dan cenderung stabil sampai pada tahun 2015. Pada Gambar 4.1 juga terlihat bahwa terdapat data *outlier* di tahun 2012 dan 2014. Data *outlier* pada tahun 2012 terdapat pada data ke-37 dan 40, yaitu curah hujan dasarian pertama pada bulan Januari dan dasarian pertama pada bulan Februari. Curah hujan di Kabupaten Banyuwangi pada dasarian pertama bulan Januari 2012 sebesar 166 mm dan curah hujan di Kabupaten Banyuwangi pada dasarian pertama Februari 2012 sebesar 111 mm. Data *outlier* pada tahun 2014 terdapat pada data ke-111. Data ke-111 merupakan curah hujan pada dasarian ke-3 bulan Januari 2014, dengan jumlah curah hujan sebesar 197. Angka ini juga merupakan curah hujan tertinggi selama lima tahun pengamatan mulai 2011 sampai 2015.



Gambar 4.2 Box Plot Data Curah Hujan Kab. Banyuwangi

Pada Gambar 4.2 dapat dilihat bahwa pada umumnya curah hujan di Kabupaten Banyuwangi cenderung tinggi pada bulan Januari, kemudian mulai turun pada bulan Maret. Curah hujan pada di bulan Juni sampai September cenderung rendah, kemudian meningkat pada bulan Oktober sampai akhir tahun. Pola tersebut tidak berlaku pada bulan Juli 2013 dan 2014, bulan Juni 2015, dan Bulan Mei 2015.

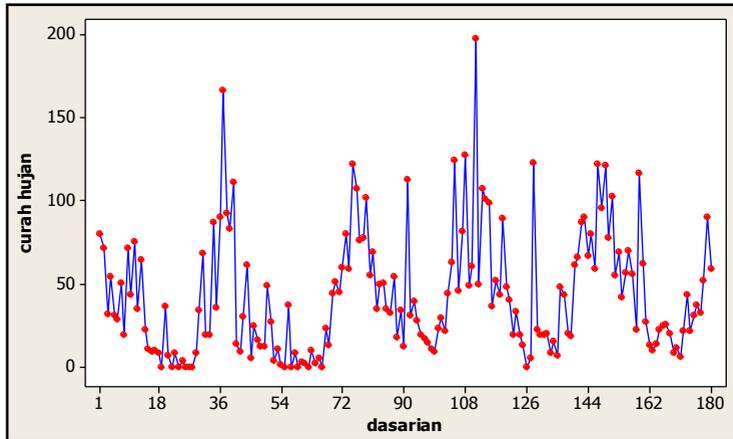
Keberadaan *outlier* pada data dapat mengakibatkan pola menjadi tidak linier. Model ARIMA merupakan fungsi linier, sehingga mungkin bukan model terbaik untuk mewakili data curah hujan di Kabupaten Banyuwangi. Oleh sebab itu, akan dilakukan juga pemodelan dengan metode lain yang mungkin lebih baik untuk memodelkan data. Salah satu model yang dapat menangkap pola non linier adalah model RBFNN. Dalam penelitian ini akan dilakukan perbandingan antara model ARIMA dan RBFNN.

4.2 Pemodelan Data Curah Hujan Kabupaten Banyuwangi dengan ARIMA

Data yang digunakan dalam penelitian ini berukuran 180. Data yang digunakan untuk membangun model ARIMA adalah data *in sample* yang berukuran 144. Data tersebut merupakan data curah hujan Kabupaten Banyuwangi mulai dari tahun 2011 sampai dengan 2014. Data tahun 2015 digunakan sebagai *out sample* untuk menguji kebaikan model.

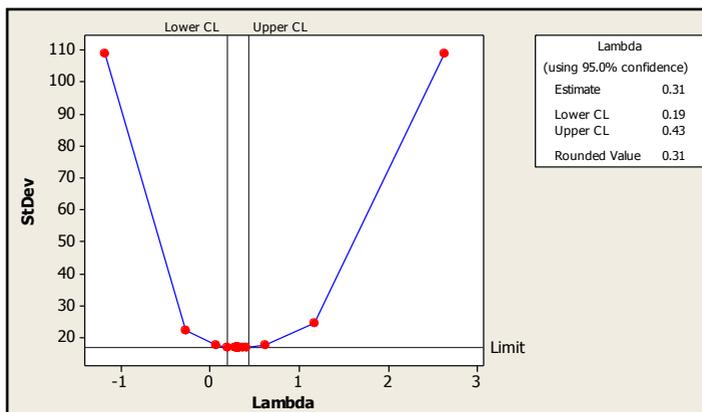
4.2.1 Pendugaan Model ARIMA

Model ARIMA mengasumsikan data yang digunakan stasioner terhadap varians dan means, oleh sebab itu tahap awal pembentukan model ARIMA adalah memeriksa stasioneritas data terhadap varians dan means. Mengingat ada data yang bernilai nol, data curah hujan terlebih dahulu ditambahkan nilai 1 agar dapat diperiksa stasioneritasnya terhadap varians dengan *box-cox plot*. *Time series plot* data curah hujan Kabupaten Banyuwangi ditampilkan pada Gambar 4.3.



Gambar 4.3 Time Series Plot Data Curah Hujan Kab. Banyuwangi

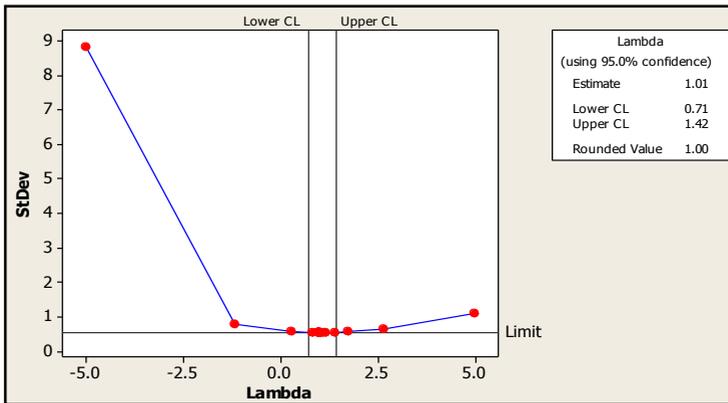
Time series plot data curah hujan Kabupaten Banyuwangi tidak stasioner terhadap varians. Hal ini terlihat dari fluktuasi data yang tidak stabil. Untuk lebih jelasnya akan diestimasi parameter *box-cox* (λ).



Gambar 4.4 Box-Cox Plot Data Curah Hujan Kabupaten Banyuwangi

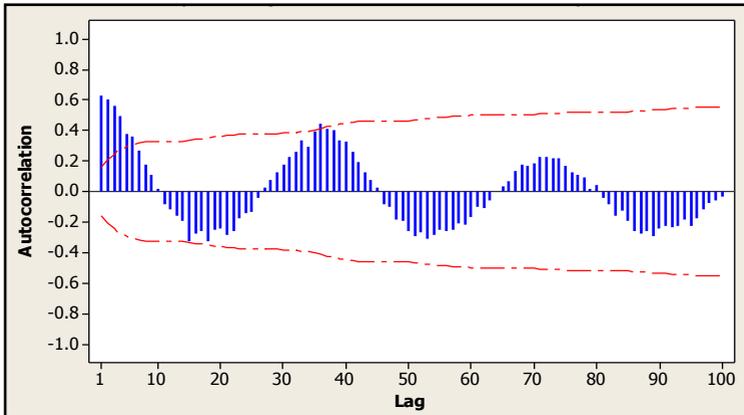
Berdasarkan *box-cox plot* pada Gambar 4.4 diketahui nilai λ tidak sama dengan 1 dan batas atas dan batas bawah nilai

rounded value (λ) tidak melewati nilai 1, sehingga disimpulkan bahwa data yang digunakan belum stasioner terhadap varians. Sebagai penanggulangan terhadap ketidakstasioneran data terhadap varians, perlu dilakukan transformasi *box-cox*. Transformasi dilakukan berdasarkan nilai λ yang diperoleh. Nilai λ yang diperoleh adalah sebesar 0,31, sehingga data ditransformasi dengan $T(Z_t) = (Z_t)^{0,31}$. *Box-cox* plot dari data yang sudah ditransformasi ditampilkan pada Gambar 4.5 .



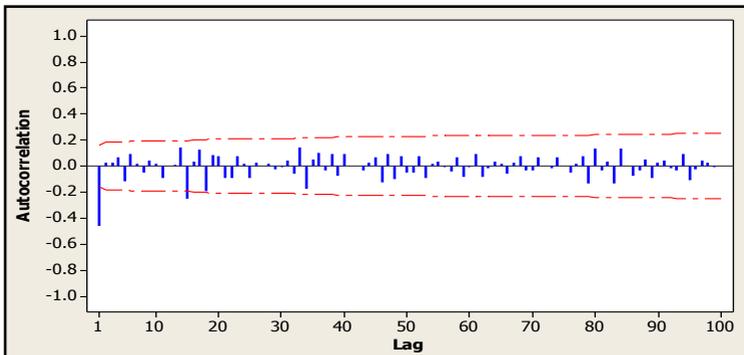
Gambar 4.5 *Box-Cox Plot* Data Curah Hujan Kabupaten Banyuwangi Setelah Transformasi

menunjukkan bahwa data yang sudah ditrans-formasi memiliki *rounded value* (λ) sebesar 1 dan batas atas dan batas bawah melewati nilai satu, sehingga dapat disimpulkan bahwa data sudah stasioner terhadap varians. Selanjutnya dilakukan pengecekan apakah data stasioner terhadap mean. Dari *time series plot* pada tampaknya data belum stasioner terhadap mean. Agar lebih jelas, pengecekan stasioneritas dilakukan dengan melihat plot ACF. Data yang sudah stasioner terhadap mean ditandai dengan plot ACF yang turun cepat menuju nol, sementara data yang belum stasioner ditandai dengan plot ACF yang turun lambat menuju nol. Plot ACF data *in sample* ditampilkan pada Gambar 4.6.

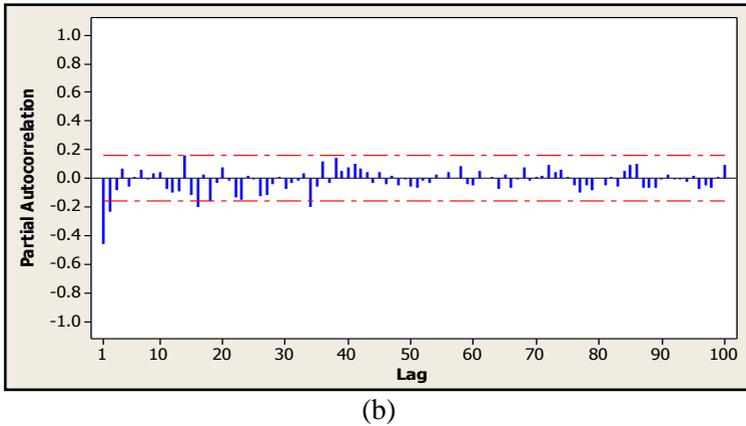


Gambar 4.6 ACF Curah Hujan Kab.Banyuwangi

Pada Gambar 4.6, plot ACF data curah hujan turun lambat menuju nol. Hal ini menunjukkan bahwa data jumlah curah hujan Kabupaten Banyuwangi belum stasioner terhadap mean. Oleh sebab itu, perlu dilakukan *differencing*. Setelah dilakukan *differencing* terhadap data *in sample*, dilihat kembali apakah data sudah stasioner terhadap mean. Plot ACF data *in sample* setelah dilakukan *differencing* ditampilkan pada Gambar 4.7 (a).



(a)



Gambar 4.7 (a) ACF dan (b) PACF Curah Hujan Kab.Banyuwangi Setelah Dilakukan *Differencing*

Pada Gambar 4.7 tampak bahwa plot PACF *cut off* pada lag 1 dan 2. Berdasarkan plot PACF dari data, diduga data mengikuti pola ARIMA(1,1,0) atau ARIMA (2,1,0). Plot ACF signifikan pada lag 1 dan 15. Berdasarkan plot ACF dari data, diduga model sementara adalah ARIMA(0,1,[15]), ARIMA(0,1,[1,15]) dan ARIMA (1,1,0). Nilai autokorelasi yang signifikan pada lag 15 yang digambarkan pada Gambar 4.7 (a) juga mengindikasikan bahwa terdapat kemungkinan data curah hujan di Kabupaten Banyuwangi pada data *in sample* memiliki pola musiman setiap 15 periode dasarian. Untuk mengetahui model yang tepat untuk data yang digunakan, dilakukan estimasi parameter untuk setiap model dan dilihat apakah parameter signifikan atau tidak. Model yang dapat digunakan adalah model yang memiliki parameter yang signifikan. Hasil estimasi parameter dan uji signifikansi parameter dari model-model tersebut dirangkum dalam Tabel 4.2.

Tabel 4.2 Estimasi Parameter dari Model Sementara

Model ARIMA	Parameter	Estimate	S.E	P-value	Kesimpulan
$(1,1,0)(0,0,1)^{15}$	ϕ_1	-0,4807	0,0696	0,000	Signifikan
	θ_1	0,3335	0,0779	0,000	Signifikan
$(0,1,1)(0,0,1)^{15}$	θ_1	0,5599	0,0658	0,000	Signifikan
	θ_1	0,3291	0,0781	0,000	Signifikan
$(2,1,0)(0,0,1)^{15}$	ϕ_1	-0,5793	0,0781	0,000	Signifikan
	ϕ_2	-0,2077	0,0785	0,009	Signifikan
	θ_1	0,3088	0,0792	0,000	Signifikan

Dari ketiga model yang dicobakan, ketiga-tiganya memiliki parameter yang signifikan. Untuk menentukan model mana yang lebih baik, selanjutnya akan dilakukan pemeriksaan apakah nilai residual sudah *white noise*.

4.2.2 Pengujian Asumsi Nilai Residual *White Noise* dan Berdistribusi Normal

Terdapat asumsi yang harus dipenuhi agar suatu model ARIMA dinyatakan mampu mewakili pola data, yaitu residual *white noise* dan residual berdistribusi normal. Asumsi nilai residual *white noise* berarti bahwa nilai residual dari model memiliki dua sifat, yaitu identik dan independen. Sifat identik berarti varians nilai residual bernilai konstan, sementara sifat independen berarti bahwa nilai residual dari model tidak berkorelasi. Berdasarkan model yang didapat pada proses sebelumnya, dihitung nilai residual dari setiap model. Nilai Residual yang didapat dari model ARIMA dinyatakan sudah memenuhi asumsi *white noise* ketika memiliki nilai autokorelasi tidak signifikan atau $P\text{-value} > (0,05)$. Pengujian asumsi residual *white noise* pada penelitian ini dilakukan dengan menggunakan

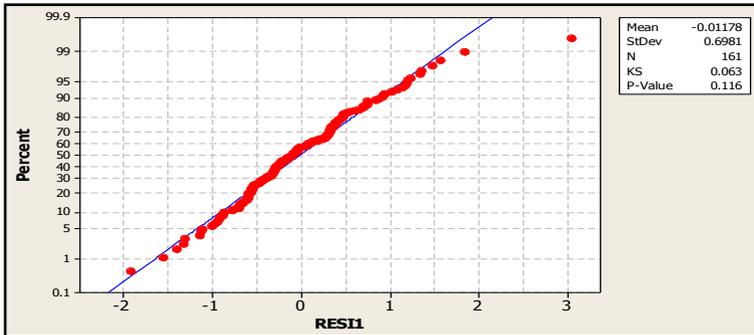
uji Ljung-Box. Hasil dari pengujian nilai residual *white noise* dijelaskan pada Tabel 4.3.

Tabel 4.3 Statistik *Ljung-Box* Nilai Residual Model ARIMA

Model	Lag	χ^2	Df	P-	Kesimpulan
(1,1,0)(0,0,1) ¹⁵	12	15,7	10	0,109	<i>White noise</i>
	24	31,4	22	0,088	
	36	44,7	34	0,104	
	48	53,7	46	0,202	
(0,1,1)(0,0,1) ¹⁵	12	9,2	10	0,511	<i>White noise</i>
	24	20,4	22	0,588	
	36	33,9	34	0,474	
	48	52,9	46	0,225	
(2,1,0)(0,0,1) ¹⁵	12	9,6	9	0,382	<i>White noise</i>
	24	20,6	21	0,485	
	36	33,0	33	0,469	
	48	45,7	45	0,445	

Berdasarkan informasi dari Tabel 4.3 diketahui bahwa model ARIMA (1,1,0)(0,0,1)¹⁵, ARIMA (0,1,0)(0,0,1)¹⁵, dan ARIMA (2,1,0)(0,0,1)¹⁵ memenuhi asumsi *white noise*. Hal ini terlihat dari nilai nilai autokorelasi nilai residual yang tidak signifikan ($P\text{-value} < 0,05$). Sampai tahap ini semua model yang sudah didapat akan diuji apakah residualnya berdistribusi normal.

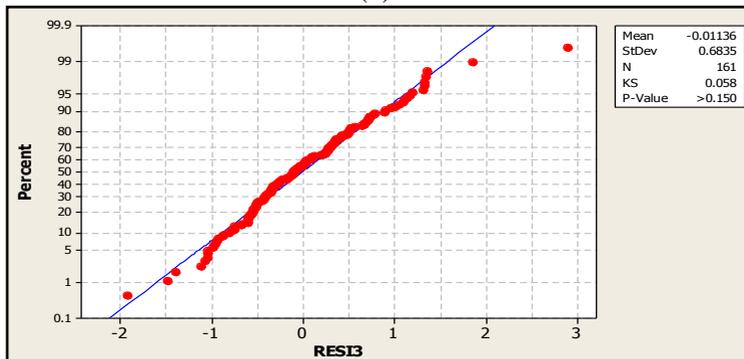
Uji distribusi normal dilakukan dengan Uji Kolmogorov-Smirnov. Plot dan hasil pengujian ditampilkan pada Gambar 4.8.



(a)



(b)



(c)

Gambar 4.8 Uji Normalitas Nilai Residual (a) $ARIMA(1,1,0)(0,0,1)^{15}$, (b) $ARIMA(0,1,0)(0,0,1)^{15}$, dan (c) $ARIMA(2,1,0)(0,0,1)^{15}$

Berdasarkan Gambar 4.7, nilai residual ketiga model yang telah lolos uji residual *white noise* juga berdistribusi normal. Hal ini diketahui dari nilai signifikansi (*P-value*) yang lebih besar dari nilai (0,05). Karena ketiga model sudah memenuhi asumsi pada model ARIMA, maka ketiga model tersebut dinyatakan baik untuk digunakan memodelkan curah hujan di Kabupaten Banyuwangi.

4.2.3 Pemilihan Model ARIMA Terbaik

Pemilihan model terbaik dalam penelitian ini menggunakan kriteria MSE, RMSE dan MAE . Model terbaik adalah model dengan nilai MSE, RMSE, dan MAE terkecil yang dihitung dari data *out sample*. Dari perbandingan nilai MSE dari ketiga model, didapat model terbaik yaitu ARIMA(2,1,0)(0,0,1)¹⁵ karena memiliki nilai MSE terkecil pada data *out sample*. Perbandingan nilai MSE, RMSE, dan MAE data *outsample* dari ketiga model dijelaskan pada Tabel 4.4.

Tabel 4.4 Perbandingan Keباikan Model-Model ARIMA

Model ARIMA	MSE	RMSE	MAE
ARIMA(1,1,0)(0,0,1) ¹⁵	371,767	19,281	13,130
ARIMA(0,1,1)(0,0,1) ¹⁵	354,116	18,818	14,209
ARIMA(2,1,0)(0,0,1) ¹⁵	344,658	18,565	12,654

Berdasarkan kriteria kebaikan model yang digunakan, yaitu MSE, RMSE, MAE, maka diketahui bahwa model ARIMA(2,1,0)(0,0,1)¹⁵ menghasilkan nilai MSE, RMSE, dan MAE terkecil. Kesimpulan yang didapat dari perbandingan tersebut adalah bahwa model terbaik adalah model ARIMA(2,1,0)(0,0,1)¹⁵.

Persamaan matematis yang dibangun dari model ARIMA(2,1,0)(0,0,1)¹⁵ adalah sebagai berikut:

$$\phi_2(B)(1 - B)\dot{Z}_t = (1 - \Theta_1 B^{15})a_t$$

$$(1 - \phi_1 B - \phi_2 B^2)(1 - B)\dot{Z}_t = (1 - \Theta_1 B^{15})a_t$$

$$(1 - \phi_1 B - \phi_2 B^2 - B + \phi_1 B^2 + \phi_2 B^3)\dot{Z}_t = (1 - \Theta_1 B^{15})a_t$$

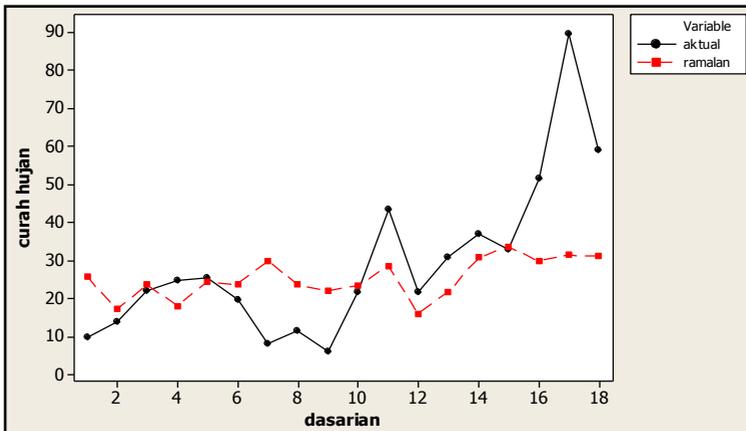
$$(1 - (\phi_1 + 1)B - (\phi_2 - \phi_1)B^2 + \phi_2 B^3)Z_t = (1 - \Theta_1 B^{15})a_t$$

$$Z_t - (\phi_1 + 1)Z_{t-1} - (\phi_2 - \phi_1)Z_{t-2} + \phi_2 Z_{t-3} = -\Theta_1 a_{t-15} + a_t$$

$$Z_t = (\phi_1 + 1)Z_{t-1} + (\phi_2 - \phi_1)Z_{t-2} - \phi_2 Z_{t-3} - \Theta_1 a_{t-15} + a_t$$

$$Z_t = 0,4207 Z_{t-1} + 0,3716 Z_{t-2} + 0,2077 Z_{t-3} - 0,3088 a_{t-15} + a_t$$

Persamaan di atas dapat diartikan bahwa peramalan jumlah curah hujan di Kabupaten Banyuwangi pada periode dasarian sekarang dipengaruhi oleh jumlah curah hujan di Kabupaten Banyuwangi pada tiga periode sebelumnya dan kesalahan peramalan jumlah curah hujan pada 15 dasarian sebelumnya. Gambar 4.9 adalah visualisasi perbandingan hasil peramalan dan data *out sampel* curah hujan di Kabupaten Banyuwangi.

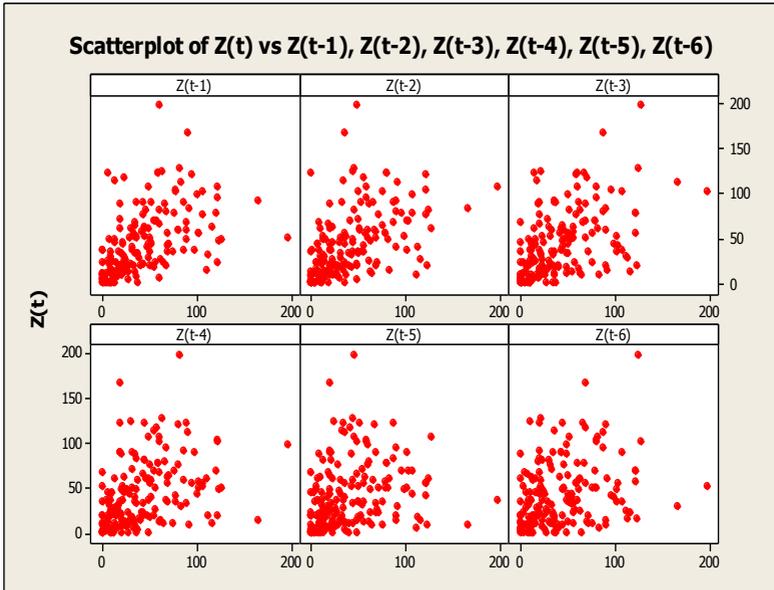


Gambar 4.9 Data Aktual dan Peramalan dengan ARIMA(0,1,1)(0,0,1)¹⁵

4.3 Uji Linieritas Data

Uji linieritas data dilakukan untuk mengetahui apakah terdapat pola linier pada data. Uji linieritas pada data curah hujan Kabupaten Banyuwangi dalam penelitian ini menggunakan Uji Terasvirta. Sebagai gambaran hubungan data curah hujan

Kabupaten Banyuwangi dengan data pada *lag-lag* yang memiliki autokorelasi yang signifikan, disajikan *scatter plot* pada Gambar 4.10.



Gambar 4.10 Scatter Plot Data Curah Hujan Terhadap *Lag-Lag* Signifikan

Perhitungan nilai statistik uji F_{hit} menghasilkan nilai sebesar 9,0078. Nilai F_{tabel} dengan nilai signifikansi (α) 5% adalah sebesar 3,0470. Nilai F_{hit} lebih besar dari nilai F_{tabel} sehingga dapat disimpulkan bahwa terdapat pola nonlinier pada data curah hujan Kabupaten Banyuwangi.

4.4 Pemodelan dengan RBFNN

Sebelum pembentukan model curah hujan Kabupaten Banyuwangi dengan metode RBFNN, terlebih dahulu dilakukan pembagian data menjadi data *training* dan *testing*. Dalam penelitian ini pembagian data *training* dan *testing* adalah masing-

masing 90% dan 10%. Data *training* digunakan untuk membentuk model dan data *testing* digunakan untuk menguji kebaikan model.

4.4.1 Penentuan Input RBFNN

Data yang digunakan untuk membangun model jaringan RBFNN adalah data *training* yang berukuran 162. Data tersebut merupakan data dasarian curah hujan Kabupaten Banyuwangi mulai dari bulan Januari tahun 2011 sampai dengan Juni 2015. Tahap awal pembentukan model RBFNN adalah menentukan matrik input. Matrik input merupakan matrik yang terdiri dari variabel-variabel input. Variabel input dalam model ini adalah *lag* yang memiliki nilai autokorelasi yang signifikan.

Pada Gambar 4.6 tampak bahwa nilai autokorelasi yang signifikan terdapat pada *lag* 1 - *lag* 6. Berdasarkan nilai autokorelasi tersebut, terdapat enam variabel input yang akan digunakan dalam model RBFNN untuk data curah hujan Kabupten Banyuwangi, yaitu Z_{t-1} , Z_{t-2} , Z_{t-3} , Z_{t-4} , Z_{t-5} , dan Z_{t-6} . Banyaknya variabel input juga merupakan banyaknya *neuron* yang terdapat pada lapisan *input* pada jaringan RBFNN yang akan terbentuk, sehingga dalam penelitian ini terdapat 6 buah *neuron* pada lapisan *input*.

4.4.2 Penentuan Jaringan Optimum

Variabel input yang telah ditentukan pada tahap sebelumnya kemudian dikelompokkan dengan metode *K-Means Clusterring*. Penentuan banyaknya kelompok data dilakukan dengan metode *trial and error*. Metode *trial and error* yang dimaksud di sini adalah dengan melakukan pengelompokan data *training* ke dalam 2 kelompok, 3 kelompok, 4 kelompok, dan seterusnya, hingga terbentuk kelompok-kelompok yang paling tidak terdiri dari dua anggota. Setiap kelompok yang terbentuk diberikan nilai pembobot yaitu nilai *center* dan nilai standar deviasi (σ) dari kelompok tersebut. Nilai *center* tersebut dihitung dari nilai pusat setiap kelompok pada setiap variabel yang

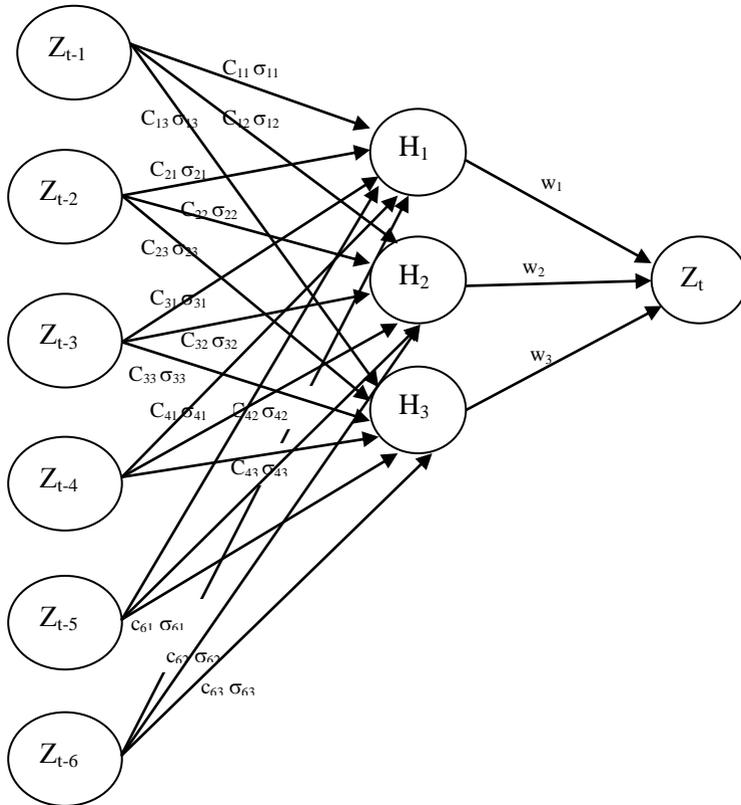
dijadikan variabel input sedangkan nilai σ merupakan standar deviasi dari setiap kelompok.

Banyaknya kelompok pada data *training* merupakan banyaknya *neuron* tersembunyi yang terdapat pada lapisan tersembunyi jaringan RBFNN. Setiap neuron pada lapisan tersembunyi diberi satu nilai pembobot (w). Nilai pembobot yang didapat dari data *training* diuji pula pada data *testing*. Nilai pembobot antara lapisan tersembunyi dan lapisan *output* dihitung dengan metode kuadrat terkecil (*Ordinary Least Square*). Dari semua kelompok yang dicobakan, diambil satu kelompok yang terbaik. Kriteria kebaikan model yang digunakan yaitu nilai *Mean Square Error* (MSE). Model terbaik adalah model yang memiliki nilai MSE terkecil pada data *training* dan data *testing*. Pada Tabel 4.5 dijelaskan uji kebaikan dari beberapa model yang terbentuk.

Tabel 4.5 Nilai MSE Model berdasarkan Banyak Kelompok yang Terbentuk

Banyak kelompok	MSE (<i>training</i>)	MSE (<i>testing</i>)
2 kelompok	1.518,5	357,97
3 kelompok	1.447,5	300,18
4 kelompok	1.329,3	762,80
5 kelompok	1.333,9	527,95
6 kelompok	3.276,4	2.399,31
7 kelompok	1.585,6	9.056,83

Berdasarkan informasi dari Tabel 4.5 diketahui bahwa dari lima pengelompokan yang dibuat, dipilih pengelompokan dengan 3 kelompok, dengan pertimbangan MSE terkecil pada data *training* dan *testing*. Dengan demikian, model RBFNN yang digunakan untuk peramalan curah hujan Kabupaten Banyuwangi dapat dibentuk dengan arsitektur 6 *neuron* pada lapisan *input*, 3 *neuron* pada lapisan tersembunyi, dan satu *neuron* pada lapisan *output*. Arsitektur jaringan RBFNN yang terbentuk dari data *testing* digambarkan pada Gambar 4.11.



Gambar 4.11 Arsitektur Jaringan RBFNN Jumlah Curah Hujan Kab. Banyuwangi

Pembobot yang digunakan pada jaringan RBFNN jumlah curah hujan Kabupaten Banyuwangi adalah sebagai berikut:

$$C = \begin{pmatrix} 77,7934 & 53,6311 & 17,6167 \\ 84,8241 & 49,4043 & 17,4761 \\ 88,1518 & 47,4875 & 17,1844 \\ 89,2987 & 45,7832 & 16,7162 \\ 89,2659 & 46,6566 & 16,7456 \\ 83,5049 & 52,3610 & 15,4184 \end{pmatrix}$$

$$\Sigma = \begin{pmatrix} 50,9877 & 39,1760 & 46,1366 \\ 55,9218 & 38,3156 & 46,2239 \\ 58,4472 & 38,0684 & 46,3453 \\ 51,0193 & 37,5187 & 45,9396 \\ 50,8262 & 37,5976 & 46,1268 \\ 50,7949 & 38,5581 & 47,0919 \end{pmatrix}$$

$$w_1 = 128,4790, w_2 = 56,0659, w_3 = 60,8272.$$

Berdasarkan arsitektur jaringan RBFNN pada Gambar 4.9, model yang terbentuk adalah sebagai berikut:

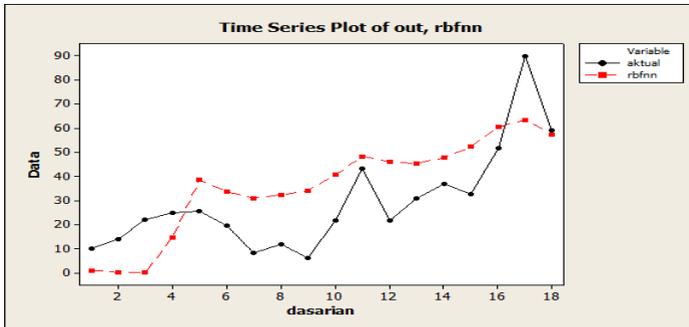
$$\hat{Z}_t = \sum_{j=1}^m w_j h_j(x)$$

$$\hat{Z}_t = 128,4790 h_1(x) + 56,0659 h_2(x) + 60,8272 h_3(x)$$

Nilai $h_j(x)$ sebagai berikut:

$$h_j(x) = \exp \left\{ - \left[\begin{array}{l} \left(\frac{x_1 - c_{1j}}{\sigma_{1j}} \right)^2 + \left(\frac{x_2 - c_{2j}}{\sigma_{2j}} \right)^2 + \left(\frac{x_3 - c_{3j}}{\sigma_{3j}} \right)^2 \\ + \left(\frac{x_4 - c_{4j}}{\sigma_{4j}} \right)^2 + \left(\frac{x_5 - c_{5j}}{\sigma_{5j}} \right)^2 + \left(\frac{x_6 - c_{6j}}{\sigma_{6j}} \right)^2 \end{array} \right] \right\}$$

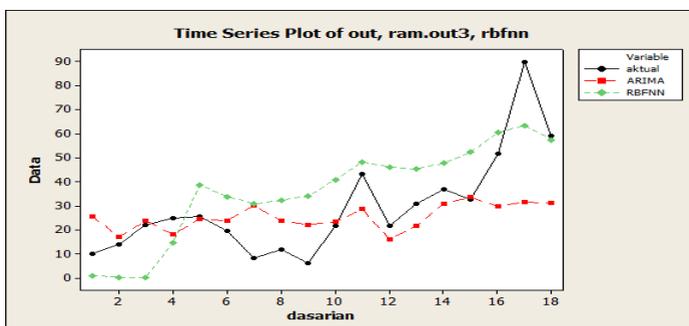
Dengan persamaan di atas, ditemukan nilai ramalan curah hujan Kabupaten Banyuwangi. Gambar 4.12 merupakan visualisasi data aktual dan ramalan dengan RBFNN.



Gambar 4.12 Data Aktual (Akt) dan Peramalan dengan RBFNN

4.5 Perbandingan ARIMA dan RBFNN

Setelah dilakukan pemodelan dengan metode ARIMA berdasarkan data *in sample* dan dengan metode RBFNN dengan data *training*, dilakukan peramalan untuk data curah hujan untuk Januari 2016 sampai dengan Juni 2016 atau 18 periode ke depan. Data curah hujan pada 18 periode setelah data *in sample* atau data *training* merupakan data *out sample* atau data *testing*. Hasil peramalan dengan RBFNN dibandingkan dengan data asli *out sample* atau data *testing*. Gambar 4.13 merupakan plot hasil peramalan data *out sample* atau data *testing* dengan metode ARIMA dan RBFNN.



Gambar 4.13 Data Aktual (akt) dan Peramalan dengan ARIMA dan RBFNN

Untuk membandingkan hasil ramalan pada data *out sample* dengan model ARIMA dan RBFNN yang telah didapat, digunakan nilai *Mean Square Error* (MSE), *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE) sebagai kriteria kebaikan model. Nilai MSE dan MAE dihitung dari data *out sample* Tabel 4.6 menampilkan perbandingan nilai MSE dan MAE dari kedua model.

Tabel 4.6 Perbandingan Kebaikan Model ARIMA dan RBFNN

	ARIMA (0,1,1)(0,0,1) ¹⁵	RBFNN	Model Terbaik
MSE	344,658	300,185	RBFNN
RMSE	18,565	17,326	RBFNN
MAE	12,654	15,722	ARIMA

Dari peramalan dengan model ARIMA didapat nilai MSE sebesar 344,658, sedangkan dari peramalan dengan model RBFNN didapat nilai MSE sebesar 300,185. Berdasarkan kedua nilai MSE yang dihasilkan, disimpulkan bahwa model RBFNN lebih baik dibandingkan model ARIMA untuk meramalkan jumlah hujan dasarian di Kabupaten Banyuwangi karena menghasilkan nilai MSE yang lebih kecil. Kesimpulan yang sama didapatkan juga dari perbandingan nilai RMSE kedua model. Selain dengan MSE dan RMSE, dilakukan pula perhitungan nilai *Mean Absolut Deviation* (MAE) untuk menentukan model mana yang paling baik. Model terbaik adalah model dengan nilai MAE terkecil. Nilai MAE dari model ARIMA sebesar 12,554, sedangkan nilai MAE dari model RBFNN sebesar 15,722. Berdasarkan nilai MAE diketahui bahwa model ARIMA lebih baik dibandingkan model RBFNN.

4.6 Peramalan Curah Hujan Di Kabupaten Banyuwangi

Model terbaik yang didapat pada proses sebelumnya digunakan untuk meramalkan jumlah curah hujan di Kabupaten Banyuwangi pada Januari - Juni 2016 atau periode 181-198. Pe-

ramalan curah hujan di Kabupaten Banyuwangi dilakukan dengan menggunakan model RBFNN. Berdasarkan model RBFNN yang terbentuk maka perhitungan nilai ramalan curah hujan Kabupaten Banyuwangi untuk periode 181 adalah sebagai berikut:

$$\hat{Z}_t = 128,4790 h_1(x) + 56,0659 h_2(x) + 60,8272 h_3(x)$$

$$\hat{Z}_{181} = 128,4790 (0,020) + 56,0659 (0,196) + 60,8272 (0,015)$$

$$\hat{Z}_{181} = 14,479$$

dengan perhitungan nilai $h_j(x)$ sebagai berikut:

$$h_j(x) = \exp \left\{ - \left[\begin{array}{l} \left(\frac{x_1 - c_{1j}}{\sigma_{1j}} \right)^2 + \left(\frac{x_2 - c_{2j}}{\sigma_{2j}} \right)^2 + \left(\frac{x_3 - c_{3j}}{\sigma_{3j}} \right)^2 \\ + \left(\frac{x_4 - c_{4j}}{\sigma_{4j}} \right)^2 + \left(\frac{x_5 - c_{5j}}{\sigma_{5j}} \right)^2 + \left(\frac{x_6 - c_{6j}}{\sigma_{6j}} \right)^2 \end{array} \right] \right\}$$

$$h_1(x) \exp \left\{ - \left[\begin{array}{l} \left(\frac{59,014 - 77,793}{50,988} \right)^2 + \left(\frac{89,698 - 84,824}{55,922} \right)^2 + \\ \left(\frac{51,610 - 88,152}{58,447} \right)^2 \\ + \left(\frac{32,780 - 89,299}{51,019} \right)^2 + \left(\frac{36,855 - 89,266}{50,826} \right)^2 + \\ \left(\frac{30,993 - 83,505}{50,795} \right)^2 \end{array} \right] \right\}$$

$$h_1(x) = \exp \left\{ - \left[\begin{array}{l} \left(\frac{-18,779}{50,988} \right)^2 + \left(\frac{4,874}{55,922} \right)^2 + \left(\frac{-36,542}{58,447} \right)^2 \\ + \left(\frac{56,519}{51,019} \right)^2 + \left(\frac{-52,411}{50,826} \right)^2 + \left(\frac{52,512}{50,795} \right)^2 \end{array} \right] \right\}$$

$$h_1(x) = 0,020$$

$$h_2(x) = \exp \left\{ - \left[\left(\frac{59,014 - 53,631}{39,176} \right)^2 + \left(\frac{89,698 - 49,403}{38,316} \right)^2 + \right. \right. \\ \left. \left. \left(\frac{51,610 - 47,487}{38,068} \right)^2 + \left(\frac{32,780 - 45,783}{37,529} \right)^2 + \left(\frac{36,855 - 46,657}{37,597} \right)^2 + \right. \right. \\ \left. \left. \left(\frac{30,993 - 52,361}{38,558} \right)^2 \right] \right\}$$

$$h_2(x) = \exp \left\{ - \left[\left(\frac{5,383}{39,176} \right)^2 + \left(\frac{40,295}{38,316} \right)^2 + \left(\frac{4,123}{38,068} \right)^2 + \right. \right. \\ \left. \left. \left(\frac{-13,003}{37,529} \right)^2 + \left(\frac{-9,802}{37,597} \right)^2 + \left(\frac{-21,368}{38,558} \right)^2 \right] \right\}$$

$$h_2(x) = 0,196$$

$$h_3(x) = \exp \left\{ - \left[\left(\frac{59,014 - 17,617}{46,136} \right)^2 + \left(\frac{89,698 - 17,476}{46,224} \right)^2 + \right. \right. \\ \left. \left. \left(\frac{51,610 - 17,184}{46,345} \right)^2 + \left(\frac{32,780 - 16,716}{45,939} \right)^2 + \left(\frac{36,855 - 16,746}{46,127} \right)^2 + \right. \right. \\ \left. \left. \left(\frac{30,993 - 15,418}{47,092} \right)^2 \right] \right\}$$

$$h_3(x) = \exp \left\{ - \left[\left(\frac{41,397}{46,136} \right)^2 + \left(\frac{72,222}{46,224} \right)^2 + \left(\frac{34,426}{46,345} \right)^2 + \left(\frac{16,064}{45,939} \right)^2 + \left(\frac{20,109}{46,127} \right)^2 + \left(\frac{15,575}{47,092} \right)^2 \right] \right\}$$

$$h_3(x) = 0,015$$

Berdasarkan perhitungan di atas, didapatkan nilai ramalan jumlah curah hujan di Kabupaten Banyuwangi pada periode ke 181 atau pada dasarian pertama bulan Januari 2016 sebesar 14,479 mm. Dengan cara yang sama, dilakukan juga perhitungan nilai ramalan jumlah curah hujan untuk periode 182 sampai 198 atau sampai bulan Juni 2016. Hasil peramalan yang diperoleh ditampilkan pada Tabel 4.7.

Tabel 4.7 Nilai Ramalan Curah Hujan Kab. Banyuwangi Januari-Juni 2016

t	Bulan	Z _t
181	Januari	14.479
182	Januari	6.663
183	Januari	2.651
184	Februari	1.539
185	Februari	1.790
186	Februari	17.645
187	Maret	42.011
188	Maret	32.589
189	Maret	31.224
190	April	31.820
191	April	33.577
192	April	40.816
193	Mei	47.619
194	Mei	45.747
195	Mei	45.378
196	Juni	47.392
197	Juni	51.937
198	Juni	60.443

(Halaman ini sengaja dikosongkan)

BAB V KESIMPULAN DAN SARAN

5.1 Kesimpulan

Setelah dilakukan analisis dan pembahasan pada bab sebelumnya, kesimpulan dari setiap analisis disajikan sebagai berikut:

1. Berdasarkan ekspolasi data data terdapat data *outlier* pada tahun 2012 dan 2014. Data *outlier* terjadi pada bulan Januari dan Februari 2012, dan Januari 2014.
2. Model yang ARIMA yang dapat mewakili data curah hujan Kabupaten Banyuwangi adalah ARIMA(2,1,0)(0,0,1)¹⁵. Model matematisnya adalah:

$$Z_t = 0,4207 Z_{t-1} + 0,3716Z_{t-2} + 0,2077Z_{t-3} - 0,3088 a_{t-15} + a_t$$

Model ini menjelaskan bahwa jumlah curah hujan di Kabupaten Banyuwangi pada periode sekarang dipengaruhi oleh jumlah curah hujan pada empat periode sebelumnya berturut-turut, dan kesalahan peramalan pada 15 periode sebelumnya.

3. Data curah hujan Kabupaten Banyuwangi dapat dimodelkan dengan metode *Radial Basis Function* (RBFNN). Model yang optimum adalah dengan 6 *neuron* pada input, 3 *neuron* pada lapisan tersembunyi, dan 1 *neuron* pada lapisan *output*.
4. Berdasarkan perbandingan MSE dan RMSE dari model ARIMA dan RBFNN, dapat dikatakan bahwa pada kasus pemodelan curah hujan di Kabupaten Banyuwangi pada tahun 2011-2015, metode RBFNN lebih baik dari pada ARIMA. Akan tetapi, berdasarkan nilai *Mean Absolute Error* (MAE), metode ARIMA lebih baik dibandingkan RBFNN.

5.2 Saran

Saran yang dapat diberikan berdasarkan penelitian yang telah dilakukan adalah sebagai berikut:

1. Penelitian selanjutnya sebaiknya menggunakan model lain yang dapat merangkum pengaruh variabel-variabel lain yang mempengaruhi curah hujan di Kabupaten Banyuwangi, mengingat Kabupaten Banyuwangi sebagai salah satu lumbung padi.
2. Inputasi data dalam penelitian ini adalah dengan nilai rata-rata pada tanggal yang sama pada tahun-tahun sebelumnya. Sebaiknya digunakan metode lain agar lebih sensitif menangkap perubahan musim dan fenomena alam yang berpengaruh atau memberi intervensi pada data curah hujan, misalnya dengan fungsi transfer atau regresi.

DAFTAR PUSTAKA

- Anwar, M., Liu, D., Macadam, I., Kelly, G. (2015). *Climate Change Impacts on Phenology and Yields of Five Broadacre Crops at Four Climatologically Distinct Locations in Australia*. *Agricultural System*, 133-144.
- Bowerman, B., & O'Connell. (1993). *Forecasting and Time Series: An Applied Approach, 3rd ed.* California: Duxbury Press.
- [BMKG] Badan Meteorologi, Klimatologi dan Geofisika. Diakses dari website www.dataonline.bmkg.go.id pada tanggal 12 Februari 2016.
- Cryer, J., & Chan, K. (2008). *Time Series Analysis with Application in R, 2nd ed.* USA: PWS-Kent Publishing (Duxbury Press).
- Fausett, L. (1994). *Fundamentals of Neural Networks (Architectures, Algorithms, dan Applications)*. Upper Saddle River, New Jersey: Prentice.
- Fithriasari, K., Iriawan, N., Ulama, B.S.S., & Sutikno. (2013). *On Multivariate Time Series Rainfall Modeling Using Time Delay Neural Network*. *International Journal of Applied Mathematics and Statistics*.
- Haviluddin & Jawahir, A. (2015). *Comparing of ARIMA and RBFNN for Short-Term Forecasting*. *International Journal of Advance in Intelligent Informatics Vol 1, No.1*, 15-22.
- Montgomery, D., Jennings, C., Kulahci, M. (2008). *Introduction to Time Series Analysis and Forecasting*. Hoboken, New Jersey: Wiley.
- Rencher, A. (2002). *Methods of Multivariate Analysis*. Amerika: A John Willey & Sons, Inc.
- Shen, W., Guo, X., Wu, Chao., & Wu, D. (2010). *Forecasting Stock Indices Using Radial Basis Function Neural*

- Networks Optimized by Artificial Fish Swarm Algorithm. Knowledge-Based System 24 , 378-385.*
- Subanar & Suhartono. (2000). *Uji Linieritas Tipe Lagrange Multiplier dengan Ekspansi Taylor untuk Deteksi Hubungan Nonlinier Pada Data Time Series.* Universitas Gadjah Mada
- Wei, W. (2006). *Time Series Analysis Univariate and Multivariate Methods.* Amerika: Addison Wesley Publishing Company, Inc.
- Wu, J., Long, J., & Liu, M. (2012). *Envolving RBF Neural Networks for Rainfall Prediction using hybrid Particle Swarm Optimization and Genetic Algorithm.* Neurocomputing 148 , 136-142.

LAMPIRAN

Lampiran 1

Data Curah Hujan Dasarian Kabupaten Banyuwangi

Thn	Bln	Curah Hujan
2011	1	80.0000
	1	71.0000
	1	32.0000
	2	54.0000
	2	31.0000
	2	28.2730
	3	50.0000
	∴	∴
	12	87.0000
	12	35.8000
	12	90.0000
2012	1	166.0000
	1	92.0000
	1	83.0000
	2	111.0000
	2	14.0000
	2	9.0000
	3	30.0000
	3	61.0000
	3	5.0000
	∴	∴
2015	11	30.993
	11	36.855
	11	32.78
	12	51.61
	12	89.698
	12	59.014

Lampiran 2

Nilai *Center* Pada K-Means Clustering

a) 2 Klaster

	Klaster1	Klaster2
$Z_{(t-1)}$	73.2304	27.3428
$Z_{(t-2)}$	76.6849	25.4515
$Z_{(t-3)}$	78.7821	24.195
$Z_{(t-4)}$	77.3999	24.124
$Z_{(t-5)}$	74.894	26.0156
$Z_{(t-6)}$	72.9559	27.3461

b) 3 Klaster

	Klaster1	Klaster2	Klaster3
$Z_{(t-1)}$	77.7934	53.6311	17.6167
$Z_{(t-2)}$	84.8241	49.4043	17.4761
$Z_{(t-3)}$	88.1518	47.4875	17.1844
$Z_{(t-4)}$	89.2987	45.7832	16.7162
$Z_{(t-5)}$	89.2659	46.6566	16.7456
$Z_{(t-6)}$	83.5049	52.361	15.4184

c) 4 Klaster

	Klaster1	Klaster2	Klaster3	Klaster4
$Z_{(t-1)}$	72.6828	34.5435	17.5844	99.0508
$Z_{(t-2)}$	85.6647	50.229	17.4492	48.4836
$Z_{(t-3)}$	90.6238	40.3074	17.1516	59.7086
$Z_{(t-4)}$	87.0867	46.8098	16.6331	50.6504
$Z_{(t-5)}$	90.3167	53.2873	15.112	40.3992
$Z_{(t-6)}$	85.8313	61.8447	15.5763	31.2577

d) 5 Klaster

	Klaster1	Klaster2	Klaster3	Klaster4	Klaster5
$Z_{(t-1)}$	67.2016	32.425	16.2417	85.9562	99.9415
$Z_{(t-2)}$	71.9896	46.3032	16.7319	39.4723	113.922
$Z_{(t-3)}$	94.6049	38.7568	17.0257	56.5858	62.1217
$Z_{(t-4)}$	81.4568	46.6144	15.3818	37.8802	94.9099
$Z_{(t-5)}$	93.7612	51.7801	14.1643	36.4439	66.6012
$Z_{(t-6)}$	92.9969	61.6825	15.5012	28.5636	47.1876

e) 6 Klaster

	Klaster1	Klaster2	Klaster3	Klaster4	Klaster5	Klaster6
$Z_{(t-)}$	54.7423	28.7432	14.278	84.2381	40.4777	81.038
$Z_{(t-)}$	75.8564	38.4077	11.6807	34.5773	79.3429	73.4096
$Z_{(t-)}$	82.7437	36.3767	16.7897	41.6606	24.015	105.635
$Z_{(t-)}$	79.807	48.9876	15.7553	36.9217	28.143	53.1187
$Z_{(t-)}$	103.8734	54.8036	14.6008	38.9183	25.2049	54.2181
$Z_{(t-)}$	98.191	67.3275	15.9357	26.5018	28.6942	53.396

f) 7 Klaster

	Klaster1	Klaster2	Klaster3	Klaster4	Klaster5
$Z_{(t-1)}$	54.7423	28.7432	14.278	84.2381	40.4777
$Z_{(t-2)}$	75.8564	38.4077	11.6807	34.5773	79.3429
$Z_{(t-3)}$	82.7437	36.3767	16.7897	41.6606	24.015
$Z_{(t-4)}$	79.807	48.9876	15.7553	36.9217	28.143
$Z_{(t-5)}$	103.8734	54.8036	14.6008	38.9183	25.2049
$Z_{(t-6)}$	98.191	67.3275	15.9357	26.5018	28.6942

	Klaster6	Klaster7
$Z_{(t-1)}$	81.038	116.2551
$Z_{(t-2)}$	73.4096	94.1152
$Z_{(t-3)}$	105.635	66.8423
$Z_{(t-4)}$	53.1187	121.3031
$Z_{(t-5)}$	54.2181	68.0813

Lampiran 3

Nilai Standar Deviasi Pada K-Means Clustering

a) 2 Klaster

	Klaster1	Klaster2
$Z_{(t-1)}$	48.04813	41.36284
$Z_{(t-2)}$	50.22456	42.15903
$Z_{(t-3)}$	51.65041	42.68369
$Z_{(t-4)}$	50.75201	42.07195
$Z_{(t-5)}$	48.9079	41.39796
$Z_{(t-6)}$	47.66425	41.00437

b) 3 Klaster

	Klaster1	Klaster2	Klaster3
$Z_{(t-1)}$	50.98777	39.17606	46.13659
$Z_{(t-2)}$	55.92177	38.31558	46.22394
$Z_{(t-3)}$	58.44722	38.06835	46.34529
$Z_{(t-4)}$	51.01934	37.52867	45.93964
$Z_{(t-5)}$	50.82623	37.59758	46.12681
$Z_{(t-6)}$	50.79495	38.55814	47.09188

c) 4 Klaster

	Klaster1	Klaster2	Klaster3	Klaster4
$Z_{(t-1)}$	47.7127	39.04243	46.15506	67.1449
$Z_{(t-2)}$	56.54465	38.44477	46.23939	38.19202
$Z_{(t-3)}$	60.35698	38.04802	46.36425	41.1153
$Z_{(t-4)}$	57.75904	37.61249	45.98799	38.17165
$Z_{(t-5)}$	60.0339	38.71866	47.10146	37.60325
$Z_{(t-6)}$	56.53725	41.74	46.99655	39.59601

d) 5 Klaster

	Klaster1	Klaster2	Klaster3	Klaster4	Klaster5
$Z_{(t-1)}$	44.58968	39.60261	46.93611	56.79002	67.88422
$Z_{(t-2)}$	47.26838	37.98747	46.6552	38.15995	79.87309
$Z_{(t-3)}$	63.51551	38.22228	46.43716	40.00278	42.11471
$Z_{(t-4)}$	53.58372	37.59438	46.72804	37.8278	63.93775
$Z_{(t-5)}$	62.77087	38.36555	47.68357	38.14352	44.02476
$Z_{(t-6)}$	62.0931	41.66936	47.04185	40.53055	37.73157

e) 6 Klaster

	Klaster1	Klaster2	Klaster3	Klaster4	Klaster5	Klaster6
$Z_{(t-)}$	38.36931	40.38987	47.31058	51.695	47.29352	70.62922
$Z_{(t-)}$	48.70602	37.98293	47.86087	38.55792	64.71209	55.07287
$Z_{(t-)}$	51.98556	37.9635	46.57814	38.02084	37.88726	74.23318
$Z_{(t-)}$	53.00262	37.45681	46.17478	39.0142	48.44637	56.64993
$Z_{(t-)}$	65.96483	40.00211	47.58161	38.05725	37.78123	53.55073
$Z_{(t-)}$	69.8814	44.47271	46.73174	40.73078	37.7264	42.06787

f) 7 Klaster

	Klaster1	Klaster2	Klaster3	Klaster4	Klaster5
$Z_{(t-1)}$	39.47102	40.82186	48.12349	55.51881	38.06577
$Z_{(t-2)}$	49.68327	38.29737	49.77992	39.03027	52.0128
$Z_{(t-3)}$	54.42973	38.61035	46.57446	37.94743	42.76716
$Z_{(t-4)}$	52.4125	37.8825	46.50483	37.97664	40.39294
$Z_{(t-5)}$	71.16813	39.12969	47.41397	37.75763	41.75027
$Z_{(t-6)}$	66.3168	44.41312	46.78083	41.35096	40.48159

	Klaster6	Klaster7
$Z_{(t-1)}$	53.21899	81.97057
$Z_{(t-2)}$	48.13296	63.09167
$Z_{(t-3)}$	72.69718	44.38765
$Z_{(t-4)}$	38.7296	86.79709
$Z_{(t-5)}$	38.96446	44.82216

Lampiran 4

***Syntax* Penghitungan Bobot RBFNN Pada Matlab**

```
x=textread('D://LJ ITS/LJ SEM 3/TA/input.txt');
y=textread('D://LJ ITS/LJ SEM 3/TA/target.txt');
sd=textread('D://LJ ITS/LJ SEM 3/TA/sd2.txt');
sd=sd';
m=textread('D://LJ ITS/LJ SEM 3/TA/m2.txt');
m=m(:,1:2);
H=rbfDesign(x',m,sdm,'g');
w=inv(H'*H)'*H'*y;
f=H*w;
e=y-f;
se=e'*e
mse=se/156
```

Lampiran 5

Syntax Peramalan Data Out Sample Curah Hujan Pada R

```

t=seq(1:198)
c=read.table("D://LJ ITS/LJ SEM 3/TA/c3.txt")#nilai center
m=as.matrix(c) #membuat matrik center
s=read.table("D://LJ ITS/LJ SEM 3/TA/s3.txt")#nilai standar
deviasi
sd=t(as.matrix(s))#membuat matrik standar deviasi
z=matrix(0,ncol=1,nrow=198)#membuat matrik untuk nilai Zt.
data=read.table("D://LJ ITS/LJ SEM 3/TA/data CH.txt",
head=T)#membaca data

#mengambil data in sample
j=seq(1:162) for (j in 1:162)
{
z[j,]=data[j,2]
}
#menghitung nilai dari fungsi gaussian untuk out sample dan
peramalan data out sample.
for (i in 163:180)
{
h1=exp(-((((z[(i-1),]-m[1,1])/sd[1,1])^2)+
(((z[(i-2),]-m[2,1])/sd[2,1])^2)+
(((z[(i-3),]-m[3,1])/sd[3,1])^2)+
(((z[(i-4),]-m[4,1])/sd[4,1])^2)+
(((z[(i-5),]-m[5,1])/sd[5,1])^2)+
(((z[(i-6),]-m[6,1])/sd[6,1])^2))))
h2=exp(-((((z[(i-1),]-m[1,2])/sd[1,2])^2)+
(((z[(i-2),]-m[2,2])/sd[2,2])^2)+
(((z[(i-3),]-m[3,2])/sd[3,2])^2)+
(((z[(i-4),]-m[4,2])/sd[4,2])^2)+
(((z[(i-5),]-m[5,2])/sd[5,2])^2)+
(((z[(i-6),]-m[6,2])/sd[6,2])^2))))

```

```

h3=exp(-(((z[(i-1),]-m[1,3])/sd[1,3])^2)+
        (((z[(i-2),]-m[2,3])/sd[2,3])^2)+
        (((z[(i-3),]-m[3,3])/sd[3,3])^2)+
        (((z[(i-4),]-m[4,3])/sd[4,3])^2)+
        (((z[(i-5),]-m[5,3])/sd[5,3])^2)+
        (((z[(i-6),]-m[6,3])/sd[6,3])^2)))

```

```

z[i,]=(128.479*h1)+(56.0659*h2)+(60.8272*h3)
}
ch=data[,2] #mengambil data aktual out sample.
outsample=ch[163:180]
ramalan.out=z[163:180,] #mengambil nilai ramalan out sample
mse=mean((outsample-ramalan.out)^2)#menghitung nilai MSE
plot(t[163:181],z[163:181,],type='l', xlab="t", lab="Z(t)",
lwd=2.2) #mrmbuat plot data ramalan out sample

```

Lampiran 6

Syntax Peramalan Data Curah Hujan Periode 181-198 Pada R

```

ch=read.table("D://LJ ITS/LJ SEM 3/TA/data CH.txt", head=T)
#membaca data curah hujan
z=matrix(0,ncol=1,nrow=198) #membuat matrik Zt
for (j in 1:180)
{z[j,]=ch[j,2]
}
#menghitung nilai fungsi Gaussian dan nilai ramalan
for (i in 181:198)
{
  h1=exp(-((((z[(i-1),]-m[1,1])/sd[1,1])^2)+
            ((z[(i-2),]-m[2,1])/sd[2,1])^2)+
            (((z[(i-3),]-m[3,1])/sd[3,1])^2)+
            (((z[(i-4),]-m[4,1])/sd[4,1])^2)+
            (((z[(i-5),]-m[5,1])/sd[5,1])^2)+
            (((z[(i-6),]-m[6,1])/sd[6,1])^2))))

  h2=exp(-((((z[(i-1),]-m[1,2])/sd[1,2])^2)+
            ((z[(i-2),]-m[2,2])/sd[2,2])^2)+
            (((z[(i-3),]-m[3,2])/sd[3,2])^2)+
            (((z[(i-4),]-m[4,2])/sd[4,2])^2)+
            (((z[(i-5),]-m[5,2])/sd[5,2])^2)+
            (((z[(i-6),]-m[6,2])/sd[6,2])^2))))

  h3=exp(-((((z[(i-1),]-m[1,3])/sd[1,3])^2)+
            ((z[(i-2),]-m[2,3])/sd[2,3])^2)+
            (((z[(i-3),]-m[3,3])/sd[3,3])^2)+
            (((z[(i-4),]-m[4,3])/sd[4,3])^2)+
            (((z[(i-5),]-m[5,3])/sd[5,3])^2)+
            (((z[(i-6),]-m[6,3])/sd[6,3])^2))))

  z[i,]=(128.479*h1)+(56.0659*h2)+(60.8272*h3)
}

```

Lampiran 7

Perhitungan Kriteria Kebaikan Model

1. Model ARIMA (0,1,1)(0,0,1)¹⁵

t	\hat{Z}_t	Z_t	e^2	$ e $
163	25.65286	9.961	246.2346	15.69186
164	17.20999	13.951	10.62103	3.258992
165	23.73103	22.118	2.601866	1.61303
166	18.08865	24.795	44.97513	6.70635
167	24.55023	25.427	0.76872	0.876767
168	23.75026	19.721	16.23497	4.029264
169	30.01344	8.147	478.1412	21.86644
170	23.72284	11.63	146.2367	12.09284
171	22.20096	6.301	252.8088	15.89996
172	23.35348	21.609	3.043214	1.744481
173	28.65683	43.301	214.4517	14.64417
174	16.10941	21.6	30.14661	5.490593
175	21.64905	30.993	87.30938	9.343949
176	30.88911	36.855	35.59185	5.96589
177	33.6293	32.78	0.721318	0.849304
178	29.87039	51.61	472.6109	21.73961
179	31.44838	89.698	3393.018	58.24962
180	31.29512	59.014	768.3365	27.71888
Σ			344.6585	12.65456

2. Model RBFNN

t	\tilde{z}_t	z_t	e^2	$ e $
163	1.007083	9.961	80.17262	8.953917
164	0.324801	13.951	185.6733	13.6262
165	0.227064	22.118	479.2131	21.89094
166	14.51853	24.795	105.6059	10.27647
167	38.59109	25.427	173.2934	13.16409
168	33.77404	19.721	197.4879	14.05304
169	30.86031	8.147	515.8944	22.71331
170	32.21751	11.63	423.8457	20.58751
171	34.08945	6.301	772.1978	27.78845
172	40.74663	21.609	366.2488	19.13763
173	48.21452	43.301	24.14272	4.913525
174	46.119	21.6	601.1814	24.519
175	45.24149	30.993	203.0194	14.24849
176	47.76783	36.855	119.0898	10.91283
177	52.30449	32.78	381.2057	19.52449
178	60.36307	51.61	76.61627	8.753072
179	63.31659	89.698	695.979	26.38141
180	57.4452	59.014	2.461135	1.568801
Σ			300.1849	15.72295

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Penulis bernama Novelina Purba, lahir di Pulian, Sumatera Utara, 12 November 1992. Penulis merupakan anak pertama dari Bapak A. Purba dan Ibu M. Saragih..Penulis menyelesaikan pendidikan D3 di Universitas Sumatera Utara

(USU) pada tahun 2010. Setelah lulus, penulis meneruskan studi dan diterima di Institut Teknologi Sepuluh Nopember (ITS) untuk jenjang Lintas Jalur S1. Penulis pernah kerja Praktek di Badan Pusat Statistik Provinsi Sumatera Utara dan Badan Tenaga Nuklir Nasional Jakarta. Penulis yakin untuk dapat menjadi seorang pemimpin harus menjaga integritas dan mau menjadi pelayan untuk orang lain untuk itu persiapkan diri sebaik mungkin selama menjadi mahasiswa. Apabila pembaca ingin berdiskusi tentang tugas akhir ini, penulis dapat dihubungi melalui email novelinagirsang@gmail.com