

**PERBANDINGAN METODE ARIMA DENGAN RBFNN DALAM
PERAMALAN RATA-RATA BANYAKNYA BILANGAN SUNSPOT**

SKRIPSI

OLEH:
MUHAMMAD AHNAF ZUFAR
NIM. 13610022



**JURUSAN MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2018**

**PERBANDINGAN METODE ARIMA DENGAN RBFNN DALAM
PERAMALAN RATA-RATA BANYAKNYA BILANGAN SUNSPOT**

SKRIPSI

Diajukan Kepada
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Matematika (S.Mat)

Oleh
Muhammad Ahnaf Zufar
NIM. 13610022

**JURUSAN MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2018**

**PERBANDINGAN METODE ARIMA DENGAN RBFNN DALAM
PERAMALAN RATA-RATA BANYAKNYA BILANGAN SUNSPOT**

SKRIPSI

Oleh

Muhammad Ahnaf Zufar

NIM. 13610022

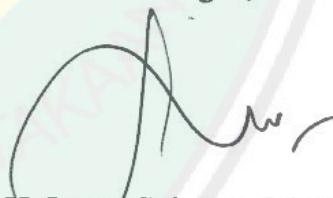
Telah Diperiksa dan Disetujui untuk Diuji
Tanggal 24 April 2018

Pembimbing I,



Mohammad Jamhuri, M.Si
NIP. 19810502 200501 1 004

Pembimbing II,



Dr. H. Imam Sujarwo, M.Pd
NIP. 19630502 198703 1 005

Mengetahui,
Ketua Jurusan Matematika



Dr. Usman Pagalay, M.Si
NIP. 19650414 200312 1 001

**PERBANDINGAN METODE ARIMA DENGAN RBFNN DALAM
PERAMALAN RATA-RATA BANYAKNYA BILANGAN SUNSPOT**

SKRIPSI

Oleh
Muhammad Ahnaf Zufar
NIM. 13610022

Telah Dipertahankan di Depan Pengaji Skripsi
dan Dinyatakan Diterima sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Sarjana Matematika (S.Mat)

Tanggal 24 April 2018

Pengaji Utama : Ari Kusumastuti, M.Pd, M.Si

Ketua Pengaji : Dr. Sri Harini, M.Si

Sekretaris Pengaji : Mohammad Jamhuri, M.Si

Anggota Pengaji : Dr. H. Imam Sujarwo, M.Pd



Mengetahui,
Ketua Jurusan Matematika



Dr. Usman Pagalay, M.Si
NIP. 19650414 200312 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Muhammad Ahnaf Zufar
NIM : 13610022
Jurusan : Matematika
Fakultas : Sains dan Teknologi
Judul Penelitian : Perbandingan Metode ARIMA dengan RBFNN dalam
Peramalan Rata-rata Banyaknya Bilangan *Sunspot*

menyatakan dengan sebenarnya bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya sendiri, bukan merupakan pengambilan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar rujukan. Apabila di kemudian hari terbukti atau dibuktikan skripsi ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan saya tersebut.

Malang, 24 April 2018
Yang membuat pernyataan,



Muhammad Ahnaf Zufar
NIM. 13610022

MOTO

لَا يُكَلِّفُ اللَّهُ نَفْسًا إِلَّا وُسْعَهَا

Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya.



PERSEMBAHAN

Skripsi ini penulis persembahkan untuk:

Kedua orang tua tersayang

Ayahanda alm Yusuf A dan ibunda Chayatur
atas limpahan kasih sayang, doa, dan membesarkan penulis
selama ini demi keberhasilan dan kesuksesan penulis
serta semua teman-teman SUBSET yang selalu mendukung



KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Segala puji syukur bagi Allah Swt atas limpahan rahmat, taufiq, hidayah dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi ini sebagai salah satu syarat untuk memperoleh gelar Sarjana Matematika di Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.

Dalam proses penyusunan skripsi ini, penulis banyak mendapatkan bimbingan dan arahan dari berbagai pihak. Untuk itu ucapan terima kasih yang sebesar-besarnya dan penghargaan yang setinggi-tingginya penulis sampaikan terutama kepada:

1. Prof. Dr. H. Abdul Haris, M.Ag, selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Sri Harini, M.Si, selaku dekan Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Usman Pagalay, M.Si, selaku ketua Jurusan Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Mohammad Jamhuri, M.Si, selaku dosen pembimbing I yang telah bersedia meluangkan waktunya untuk memberikan arahan, motivasi, dan berbagai pengalaman yang berharga kepada penulis.
5. Dr. H. Imam Sujarwo, M.Pd, selaku dosen pembimbing II yang telah banyak memberikan arahan, motivasi, dan berbagai ilmunya kepada penulis.
6. Segenap sivitas akademika Jurusan Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang terutama seluruh dosen, terima kasih atas segala ilmu yang telah diberikan.

7. Ayah dan ibu, serta segenap keluarga yang senantiasa memberikan doa, semangat, serta motivasi kepada penulis.
8. Seluruh teman-teman di Jurusan Matematika angkatan 2013, terima kasih atas motivasi, semangat kepada penulis.
9. Semua pihak yang ikut membantu dalam menyelesaikan skripsi ini.

Akhirnya penulis berharap semoga skripsi ini bermanfaat bagi penulis dan pembaca.

Wassalamu 'alaikum Warahmatullahi Wabarakatuh

Malang, April 2018

Penulis

DAFTAR ISI

HALAMAN JUDUL

HALAMAN PENGAJUAN

HALAMAN PERSETUJUAN

HALAMAN PENGESAHAN

HALAMAN PERNYATAAN KEASLIAN TULISAN

HALAMAN MOTO

HALAMAN PERSEMBAHAN

KATA PENGANTAR..... vii

DAFTAR ISI..... ix

DAFTAR TABEL xi

DAFTAR GAMBAR..... xii

ABSTRAK xiii

ABSTRACT xiv

ملخص..... xv

BAB I PENDAHULUAN

1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	4
1.5 Batasan Masalah	4
1.6 Sistematika Penulisan	5

BAB II KAJIAN TEORI

2.1 Model <i>Time Series</i>	6
2.2 Stasionalitas	7
2.3 Fungsi Autokorelasi	8
2.3.1 Autocorrelation Function (ACF)	8
2.3.2 Partial Autocorrelation Function (PACF)	8
2.4 Metode <i>Autoregresive Integrated Moving Average</i> (ARIMA).....	10
2.4.1 <i>Autoregresive</i> (AR)	10
2.4.2 <i>Moving Average</i> (MA).....	11
2.4.3 <i>Autoregresive Moving Average</i> (ARMA).....	12
2.4.4 <i>Autoregresive Integrated Moving Average</i> (ARIMA).....	12
2.4.5 <i>Seasonal Autoregresive Integrated Moving Average</i> (SARIMA)	13
2.5 Tahap-tahap dalam ARIMA	14
2.5.1 Identifikasi Model	14
2.5.2 Penaksiran Parameter	15

2.5.3 Uji Signifikansi Model	15
2.5.4 Peramalan	16
2.6 <i>Radial Basis Function Neural Network (RBFNN)</i>	16
2.7 Arsitektur RBFNN	17
2.8 Fungsi Aktivasi	18
2.9 Metode Pembelajaran dan Pelatihan	19
2.10 Ketepatan Model Peramalan	19
2.11 Bintik Matahari (<i>Sunspot</i>)	20
2.12 Bilangan <i>Sunspot</i>	22
2.13 Kajian Islam	23
2.13.1 Kajian Islam tentang Matahari	23
2.13.2 Kajian Islam Tentang Peramalan	24
BAB III METODE PENELITIAN	
3.1 Pendekatan Penelitian	26
3.2 Identifikasi Variabel	26
3.3 Jenis dan Sumber Data	26
3.4 Metode Analisis	27
3.5 Langkah-langkah Penelitian	27
3.5.1 Langkah-langkah RBF	27
3.5.2 Langkah-langkah ARIMA	28
BAB IV HASIL DAN PEMBAHASAN	
4.1 Peramalan dengan Model ARIMA	29
4.1.1 <i>Plot</i> Data Bilangan <i>Sunspot</i>	29
4.1.2 Identifikasi Model	30
4.1.3 Pendugaan Parameter	34
4.1.4 Uji Kesesuaian Model	37
4.1.5 Peramalan ARIMA	39
4.2 Peramalan dengan RBFNN	43
4.2.1 Identifikasi Model	43
4.2.2 Pembagian Data	43
4.2.3 Menentukan Jaringan Optimum	43
4.2.4 Penaksiran Parameter	44
4.2.5 Uji Kesesuaian Model	46
4.2.6 Peramalan	47
4.3 Perbandingan Hasil Ramalan dari ARIMA dengan RBFNN	51
4.4 Persepektif Islam	53
4.4.1 Perseptif Islam mengenai Matahari	53
4.4.2 Perseptif Islam Mengenai Ramalan	54
BAB V PENUTUP	
5.1 Kesimpulan	57
5.2 Saran	58
DAFTAR PUSTAKA	59
LAMPIRAN-LAMPIRAN	
RIWAYAT HIDUP	

DAFTAR TABEL

Tabel 2.1	Pola Grafik ACF dan PACF.....	15
Tabel 4.1	Uji Signifikansi Parameter	34
Tabel 4.2	Nilai $p - value$ dari uji Q	37
Tabel 4.3	Hasil <i>error</i> ARIMA setiap siklus.....	40
Tabel 4.4	Hasil Peramalan ARIMA	41
Tabel 4.5	Hasil SSE dan MAPE dari <i>neuron</i> tersembunyi	44
Tabel 4.6	Pembagian data x	45
Tabel 4.7	Data y	45
Tabel 4.8	Hasil <i>error</i> RBFNN setiap siklus.....	49
Tabel 4.9	Hasil peramalan RBFNN	49
Tabel 4.10	Hasil perbandingan data aktual, ARIMA dan RBFNN.....	51

DAFTAR GAMBAR

Gambar 2.1	Arsitektur RBFNN	17
Gambar 2.2	Bentuk <i>Sunspot</i> dalam Tiga Dimensi	20
Gambar 2.3	<i>Umbra</i> pada Bagian Dalam dan <i>Penumbra</i> pada Bagian Luar	21
Gambar 3.1	<i>Flowchart</i> alur RBFNN.....	27
Gambar 3.2	<i>Flowchart</i> alur ARIMA.....	28
Gambar 4.1	<i>Plot</i> Bulanan <i>Sunspot</i>	29
Gambar 4.2	<i>Plot</i> Data tehadap trend	29
Gambar 4.3	<i>Plot ACF</i> data asli	30
Gambar 4.4	<i>Plot</i> Data Transformasi	31
Gambar 4.5	<i>Plot differencing</i>	31
Gambar 4.6	Grafik ACF.....	32
Gambar 4.7	<i>Plot PACF</i>	33
Gambar 4.8	<i>Plot ACF Residual</i>	38
Gambar 4.9	<i>Plot PACF Residual</i>	38
Gambar 4.10	<i>Plot</i> Data Asli dan Peramalan	39
Gambar 4.11	<i>Plot</i> Hasil Residual.....	40
Gambar 4.12	<i>Plot</i> Hasil Peramalan ARIMA.....	42
Gambar 4.13	<i>Plot ACF</i> data asli	43
Gambar 4.14	<i>Plot ACF</i> hasil <i>residual</i>	47
Gambar 4.15	<i>Plot PACF</i> hasil <i>residual</i>	47
Gambar 4.16	<i>Plot</i> data dan hasil peramalan.....	48
Gambar 4.17	<i>Plot</i> Hasil Residual.....	48
Gambar 4.18	<i>Plot</i> hasil peramalan RBFNN.....	50
Gambar 4.19	<i>Plot</i> Data Aktual, ARIMA dan RBFNN	51

ABSTRAK

Zufar, Muhammad Ahnaf. 2018. **Perbandingan Metode ARIMA dengan RBFNN dalam Peramalan Rata-rata Banyaknya Bilangan Sunspot.**

Jurusan Matematika fakultas Sains dan Teknologi Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang.

Pembimbing: (I) Mohammad Jamhuri, M.Si.

(II) Dr. H. Imam Sujarwo, M.Pd

Kata Kunci: peramalan (*forecasting*), ARIMA, Autoregressive (AR), Integrated (I), Moving Average (MA), RBFNN.

ARIMA dan RBFNN merupakan salah satu metode yang dapat digunakan dalam peramalan *time series* seperti bilangan *sunspot*. Dalam menganalisis data yang diperoleh dari BPAA LAPAN Pasuruan, maka langkah yang dilakukan yaitu mendeskripsikan data, identifikasi, pendugaan parameter, uji signifikansi, kemudian meramalkan untuk periode mendatang.

Metode ARIMA adalah salah satu metode peramalan yang ada dalam *time series*, metode ini termasuk dari jenis model kausal, yang biasanya menggunakan analisis regresi untuk menentukan variabel yang signifikan mempengaruhi variabel dependen. Metode ARIMA berasal dari penggabungan antara Autoregresive (AR) dan Moving Average (MA). Model umum untuk ARIMA yang digunakan dalam peramalan adalah

$$X_t = X_{t-1} - 0,0497 + 0,1541X_{t-11} - 0,1541X_{t-12} - 0,5344\alpha_{t-1} - 0,9585\alpha_{t-11}$$

RBFNN adalah salah satu model *Neural Network* (NN) yang digunakan untuk menyelesaikan permasalahan nonlinear. Desain dari RBFNN adalah model NN yang mentransformasikan *input* secara nonlinear dengan menggunakan fungsi aktivasi multikuadratik pada lapisan tersembunyi sebelum diproses secara linear di lapisan *output*. Sehingga model umum RBFNN adalah

$$\begin{aligned}f(x) = & -178,3 - 2.781,2 \times 10^3 \psi_1(x, c_1) - 131,5 \psi_2(x, c_2) - 11,7 \psi_3(x, c_3) \\& + 852 \psi_4(x, c_4) + 9,3 \psi_5(x, c_5) + 3,6(x, c_6) - 138,9 \psi_7(x, c_7) \\& + 334,3 \psi_8(x, c_8) + 36,9 \psi_9(x, c_9) + 2.268 \psi_{10}(x, c_{10})\end{aligned}$$

Dengan membandingkan kedua metode ini, diperoleh metode mana yang lebih baik dalam meramalkan *sunspot*.

ABSTRACT

Zufar, Muhammad Ahnaf. 2017. **Comparison of ARIMA Method with RBFNN in Average Forecasting of Number of Sunspot Numbers.** Department of Mathematics Faculty of Science and Technology State Islamic University (UIN) Maulana Malik Ibrahim Malang.

Counselor: (I) Mohammad Jamhuri, M.Si.

(II) Dr. H. Imam Sujarwo, M.Pd

Keywords: forecasting, ARIMA, Autoregressive (AR), Integrated (I), Moving Average (MA), RBFNN.

ARIMA and RBFNN is one of the methods that can be used in time series forecasting such as sunspot number. In releasing data obtained from BPAA LAPAN Pasuruan, the steps taken are to describe the data, identification, parameter estimation, significance test, and then forecast for the coming period.

ARIMA method is one of the forecasting methods that exist in the time series, this method includes from the type causal model, which usually uses regression analysis to determine the variables that significantly affect the dependent variable. The ARIMA method is derived from the merger between Autoregresive (AR) and Moving Average (MA). The general model for ARIMA used in forecasting is

$$X_t = X_{t-1} - 0,0497 + 0,1541X_{t-11} - 0,1541X_{t-12} - 0,5344\alpha_{t-1} - 0,9585\alpha_{t-11}$$

RBFNN is one of the Neural Network (NN) models used to solve nonlinear problems. The design of RBFNN is an NN model that transforms inputs nonlinearly by using a multiquadratic activation function in a hidden layer before it is linearly coated in output. So the general model of RBFNN is

$$\begin{aligned} f(x) = & -178,3 - 2,781,2 \times 10^3 \psi_1(x, c_1) - 131,5 \psi_2(x, c_2) - 11,7 \psi_3(x, c_3) \\ & + 852 \psi_4(x, c_4) + 9,3 \psi_5(x, c_5) + 3,6(x, c_6) - 138,9 \psi_7(x, c_7) \\ & + 334,3 \psi_8(x, c_8) + 36,9 \psi_9(x, c_9) + 2,268 \psi_{10}(x, c_{10}) \end{aligned}$$

By comparing these two methods, which method is better in predicting the sunspot.

ملخص

زوفار، محمد أهناف. 2018. مقارنة طريقة ARIMA مع RBFNN في متوسط التنبؤ بعدد أرقام البقع الشمسية. بحث جامعي. كلية العلوم والتكنولوجيا. جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. مشرف: (١) محمد جامهوري، (٢) دكتور امام سوجارو.

الكلمة الرئيسية: التنبؤ ، ARIMA ، Autoregressive ، Integrated ، Moving Average ، RBFNN

الارام و RBFNN هي إحدى الطرق التي يمكن استخدامها في التنبؤ بالسلسلة الزمنية فضلاً مثل رقم البقع الشمسية. وفي البيانات التي تم الحصول عليها من BPAA LAPAN، فإن الحركة تقدم اي وصف للبيانات ، وتحديد الهوية، ومعايير التنبؤ، واختبار الاهمية، ثم توقع في الفترة القادمة.

طريقه التنبؤ ARIMA هي الطريقة التي هي موجودة في سلسله زمنيه ، وهذه الطريقة من النموذج السبجي، والتي تستخدم عاده تحليل الانحدار لتحديد المتغيرات التي تؤثر على المتغير التابع كبيره. وتستمد طريقه ARIMA من الاندماج بين AR (Autoregressive) و Moving (Moving Average).

ويستخدم نموذج عام للتنبؤ ب ARIMA في

$$X_t = X_{t-1} - 0,0497 + 0,1541X_{t-11} - 0,1541X_{t-12} - 0,5344\alpha_{t-1} - 0,9585\alpha_{t-11}$$

RBFNN هو نموذج واحد من الشبكة العصبية (NN) المستخدمة لحل المشاكل غير الخطية. تصميم RBFNN هو نموذج الشبكة العصبية يقوم بتحويل المدخلات بطريقة غير خطية باستخدام دالة التنشيط متعدد الكادرات في الطبقة المخفية قبل معالجتها خطياً في طبقة الخرج.

لذلك فإن النموذج العام لـ RBFNN هو

$$\begin{aligned} f(x) = & -178,3 - 2.781,2 \times 10^3 \psi_1(x, c_1) - 131,5 \psi_2(x, c_2) \\ & - 11,7 \psi_3(x, c_3) + 852 \psi_4(x, c_4) + 9,3 \psi_5(x, c_5) \\ & + 3,6(x, c_6) - 138,9 \psi_7(x, c_7) + 334,3 \psi_8(x, c_8) \\ & + 36,9 \psi_9(x, c_9) + 2.268 \psi_{10}(x, c_{10}) \end{aligned}$$

من خلال مقارنة هاتين الطريقتين ، أيهما أفضل في توقع البقع الشمسية.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sunspot merupakan daerah gelap pada matahari dan terletak di lapisan fotosfer yang memiliki medan magnet yang sangat besar yaitu sekitar 1.000 sampai 4.000 Gauss ($1 \text{ Gauss} = 1 \times 10^{-4}$ Tesla). Suhu di *sunspot* relatif lebih rendah dibandingkan dengan suhu di daerah lain yang ada di permukaan matahari.

Pada tahun 1927 Yule telah mempelopori analisis *time series* pada data bilangan bintik matahari sebagai fenomena alam yang penting. Menurut para ilmuwan, periode satu siklus matahari biasanya berkisar antara 9 sampai 15 tahun, tetapi berdasarkan pengamatan, rata-rata siklus matahari adalah 11 tahun. Pada saat ini matahari masuk pada siklus ke-24.

Dalam pengamatan *sunspot*, indeks yang paling penting adalah bilangan *sunspot*. Dimana jumlah bilangan *sunspot* dapat mengindikasikan tingkat aktivitas yang ada di matahari. Jika jumlah *sunspot* banyak maka aktivitas di matahari akan tinggi, tetapi jika jumlah *sunspot* sedikit maka aktivitas di matahari akan rendah. Kondisi *sunspot* ini akan berdampak pada lingkungan antariksa dan mempengaruhi iklim yang ada di bumi serta beberapa aktivitas manusia. Sehingga diperlukan tambahan informasi dalam mengambil keputusan untuk mengatasi masalah tersebut (Maspupu, 2011).

Salah satu cabang ilmu matematika yang membahas tentang masalah di atas adalah ilmu statistik. Pada ilmu statistik, salah satu metode yang

dikembangkan dalam peramalan adalah *time series*. Ada 2 bagian dalam teknik peramalan *time series* yaitu model peramalan berdasarkan model matematika statistik dan model peramalan berdasarkan kecerdasan buatan (Wiyanti and Pulungan, 2012).

Salah satu model peramalan berdasarkan model matematika statistik adalah ARIMA. ARIMA sering digunakan dalam peramalan *time series*, karena ketepatannya yang baik dalam peramalan jangka pendek dan data *time series nonstasioner*. Tetapi ARIMA kurang baik ketepatannya untuk peramalan jangka panjang dan jika terdapat komponen nonlinier *time series* pada data pengamatan maka model ARIMA mengalami penurunan keakuratan.

Hal ini berbeda dengan *neural network* pada kecerdasan buatan yang dapat digunakan untuk memprediksi *time series* nonlinier salah satunya adalah *Radial Basis Function Neural Network* (RBFNN). RBFNN sangat baik ketika digunakan untuk menyelesaikan permasalahan komponen *nonstasioner* dan nonlinier. Tetapi dalam RBFNN biasanya ditemukan hasil *output* yang baik untuk data yang dilatih saja, sementara untuk data yang divalidasi hasilnya kurang bagus.

Model ARIMA (p,d,q) merupakan penggabungan antara model *Autoregresive* (AR), *Integrated* (I) , dan *Moving Average* (MA) dimana orde dari AR adalah p dan orde dari MA adalah q , sedangkan d adalah *difference*. Dalam menyusun model ini, hal pertama adalah membuat *plot* data, kemudian menganalisis data sehingga diperoleh model terbaik. Hasil model terbaik akan digunakan untuk peramalan periode kedepan.

Model RBFNN terdiri dari lapisan *input*, lapisan *hidden*, dan lapisan *output*. Bobot pada RBFNN terdapat pada jaringan yang terhubung yaitu lapisan

hidden ke lapisan *output*. Dimana pada lapisan *hidden* terdapat fungsi aktivasi yang mengeluarkan nilai berupa persamaan nonlinier, sedangkan pada lapisan *output* akan menghasilkan nilai berupa persamaan linier.

Penelitian sebelumnya terkait masalah bilangan *sunspot* pernah dilakukan oleh John Maspupu (2011) dimana dia memprediksi jumlah bintik matahari menggunakan konsep beda hingga dan model Xanthaxis. Pada penelitian ini diperoleh hasil prediksi tentang kondisi awal dan akhir matahari pada siklus ke-24 serta kondisi maksimum matahari pada siklus ke-24.

Berdasarkan uraian di atas, peneliti tertarik untuk melakukan penelitian terkait perbandingan metode ARIMA dengan RBFNN yang akan digunakan untuk meramalkan rata-rata bilangan *sunspot*.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, maka dapat ditentukan rumusan masalah yaitu bagaimana hasil perbandingan antara metode ARIMA dengan RBFNN dalam meramalkan rata-rata bilangan *sunspot*.

1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah untuk mengetahui hasil perbandingan metode ARIMA dengan RBFNN dalam meramalkan rata-rata bilangan *sunspot*.

1.4 Manfaat Penelitian

Manfaat yang dapat diambil dari pelaksanaan tugas akhir ini yaitu dapat menambah wawasan dan pengetahuan tentang metode peramalan dan mengetahui metode terbaik dalam peramalan bulanan *sunspot*, serta mampu mengaplikasikan pengetahuan matematika untuk memperoleh informasi lebih dini tentang aktivitas matahari terutama *sunspot* untuk masa-masa yang akan datang dan dapat dijadikan acuan untuk mengambil langkah yang tepat dalam mengambil suatu keputusan.

1.5 Batasan Masalah

Untuk menghindari agar permasalahan tidak semakin meluas maka penulis membatasi pembahasan penelitian pada masalah sebagai berikut:

1. Data rata-rata bilangan *sunspot* yang diambil bersumber dari BPAA LAPAN Pasuruan.
2. Data yang diambil adalah data rata-rata bilangan *sunspot* per bulan, terhitung mulai Januari 1987 sampai Desember 2016.
3. Metode analisis data yang digunakan adalah metode ARIMA dan RBFNN dengan model ARIMA $(p, d, q)(P, D, Q)^s$.

1.6 Sistematika Penulisan

Sistematika penulisan yang digunakan dalam penulisan skripsi ini adalah sebagai berikut:

Bab I Pendahuluan

Pada bab ini akan diuraikan tentang latar belakang, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, metodologi penelitian dan sistematika penulisan.

Bab II Kajian Teori

Pada bab ini dibahas mengenai teori-teori yang digunakan sebagai acuan dalam pembahasan masalah yang diambil dari berbagai literatur.

Bab III Metode Penelitian

Pada bab ini berisi tentang pendekatan penelitian, identifikasi variabel, jenis dan sumber data, metode analisis serta langkah-langkah yang digunakan.

Bab IV Pembahasan

Bab ini merupakan bab inti dari penulisan yang berisi tentang pembahasan penelitian dari hasil pencarian data.

Bab V Penutup

Pada bab ini berisi tentang kesimpulan dan saran dari hasil pembahasan dan penelitian yang telah dilakukan.

BAB II

KAJIAN TEORI

ARIMA dan RBFNN merupakan metode yang digunakan dalam *forecasting* dimana ARIMA didasarkan pada model matematika statistik dan RBFNN merupakan model peramalan yang didasarkan pada kecerdasan buatan. *Autokorelasi* dibutuhkan untuk menentukan koefisien korelasi pada deret berkala melalui ACF dan PACF.

2.1 Model *Time Series*

Time series merupakan kumpulan data dari waktu ke waktu yang menggambarkan suatu peristiwa/kegiatan/keadaan. Dimana interval atau jarak dari tiap waktu sama (Boediono and Wayan, 2004).

Salah satu langkah penting dalam memilih metode peramalan adalah mempertimbangkan pola data sehingga metode peramalan yang sesuai dengan data tersebut dapat bermanfaat. Berikut ini adalah pola-pola deret berkala yang telah dikenal (Hanke and Dean, 2005):

1. Pola Data Horizontal

Pola horizontal terjadi ketika nilai-nilai data berfluktuasi di sekitar nilai rata-rata yang konstan. Penjualan produk yang tidak naik ataupun turun secara signifikan dalam suatu rentang waktu tertentu.

2. Pola Data Trend

Pola data trend didefinisikan sebagai kenaikan atau penurunan pada suatu deret waktu dalam selang periode waktu tertentu.

3. Pola Data Musiman

Pola data musiman terjadi ketika data dipengaruhi faktor musiman yang signifikan sehingga data naik dan turun dengan pola yang berulang dari satu periode ke periode berikutnya. Data penjualan buah-buahan dan konsumsi listrik menunjukkan pola data tipe ini.

4. Pola Data Siklus

Pola data siklus didefinisikan sebagai fluktuasi data berbentuk gelombang sepanjang periode yang tidak menentu.

2.2 Stasioneritas

Suatu data runtut waktu dikatakan stasioner jika nilai data runtut waktu tidak memiliki *trend* dan unsur musiman atau dengan berjalanannya waktu rata-rata dan variannya tetap. Kelompok model ARIMA hanya dapat diterapkan pada data runtut waktu yang stasioner. Jika data runtut waktu tidak stasioner maka biasanya distasionerkan melalui transformasi seperti *differencing* (Mulyono, 2000).

Menurut Wei (2006), stasioneritas dibagi menjadi dua, yaitu:

1. Stasioneritas dalam rata-rata

Stasioner dalam rata-rata merupakan fluktuasi data yang berada di sekitar nilai rata-rata yang konstan, tidak bergantung pada waktu dan variansi dari fluktuasi tersebut. Dari bentuk *plot* data seringkali dapat diketahui bahwa data tersebut stasioner atau tidak stasioner. Apabila dilihat dari *plot ACF*, maka nilai-nilai autokorelasi dari data stasioner akan turun menuju nol sesudah *time lag* (selisih waktu) kedua atau ketiga.

2. Stasioneritas dalam variansi

Data *time series* dikatakan stasioner dalam variansi apabila struktur data dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah. Secara visual untuk melihat hal tersebut dapat dibantu dengan menggunakan *plot time series*, yaitu dengan melihat fluktuasi data dari waktu ke waktu.

2.3 Fungsi Autokorelasi

2.3.1 Autocorrelation Function (ACF)

Menurut (Brockwell and Davis, 2002), koefisien fungsi autokorelasi dapat diduga dengan rumus:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} \quad (2.1)$$

dimana:

$$k = 0, \pm 1, \pm 2, \dots$$

$\hat{\rho}_k$: koefisien autokorelasi pada *lag* ke- k

$\hat{\gamma}_k$: fungsi autokovarian pada *lag* k , $\hat{\gamma}_k = \left(\frac{1}{n}\right) \sum_{t=1}^{n-k} (X_t - \bar{X})(X_{t-k} - \bar{X})$

$\hat{\gamma}_0$: ragam dari X_t , $\hat{\gamma}_0 = \left(\frac{1}{n}\right) \sum_{t=1}^n (X_t - \bar{X})^2$

2.3.2 Partial Autocorrelation Function (PACF)

Autokorelasi parsial merupakan pengembangan dari autokorelasi, yaitu dengan cara menghilangkan dependensi linier pada variabel X_{t+1}, X_{t+2}, \dots , dan X_{t+k-1} , sehingga diperoleh bentuk korelasi baru yang dinyatakan sebagai berikut (Wei, 2006):

$$\text{corr}(X_t, X_{t+k} | X_{t+1}, X_{t-2}, \dots, X_{t+k-1}) \quad (2.2)$$

Autokorelasi parsial antara Y_t dan Y_{t+k} akan sama dengan autokorelasi antara $(X_t - \hat{X}_t)$ dan $(X_{t+k} - \hat{X}_{t+k})$ sehingga diperoleh nilai autokorelasi parsial,

$$\rho_k = \frac{\text{Cov}\left[(X_t - \bar{X}_t)(X_{t+k} - \bar{X}_{t+k})\right]}{\sqrt{\text{Var}(X_t - \bar{X}_t)}\sqrt{\text{Var}(X_{t+k} - \bar{X}_{t+k})}} \quad (2.3)$$

Autokorelasi parsial X_t dan X_{t+k} dapat diturunkan dari model regresi liniear, dengan variabel *dependent* X_{t+k} dari proses stasioner dengan *mean* nol yang diregresikan dengan k lag variabel $X_{t+k-1}, X_{t+k-2}, \dots$, dan X_t , maka:

$$X_{t+k} = \phi_{k1}X_{t+k-1} + \phi_{k2}X_{t+k-2} + \dots + \phi_{kk}X_{t+k-k} + e_{t+k} \quad (2.4)$$

dengan ϕ_{kk} merupakan parameter regresi dan e_{t+k} adalah nilai *error* dengan *mean* 0, dan tidak berkorelasi dengan X_{t+k-j} untuk $j = 1, 2, \dots, k$. Dengan mengalikan X_{t+k-1} pada kedua ruas persamaan (2.4) dan menghitung nilai harapannya (*expected value*), diperoleh:

$$\gamma_j = \phi_{k1}\gamma_{j-1} + \phi_{k2}\gamma_{j-2} + \dots + \phi_{kk}\gamma_{j-k} \quad (2.5)$$

dan

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k} \quad (2.6)$$

Untuk $j = 1, 2, \dots, k$, diperoleh sistem persamaan berikut:

$$\begin{aligned} \rho_1 &= \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{j-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \dots + \phi_{kk}\rho_{j-2} \\ &\vdots \\ \rho_k &= \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}\rho_0 \end{aligned} \quad (2.7)$$

Dengan menggunakan aturan *Cramer*, berturut-turut untuk $k = 1, 2, \dots$, diperoleh

$$\begin{aligned}
 \phi_{11} &= \rho_1 \\
 \phi_{22} &= \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} \\
 \phi_{33} &= \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} \\
 &\vdots \\
 \phi_{kk} &= \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & 1 \end{vmatrix}}
 \end{aligned} \tag{2.8}$$

Karena ϕ_{kk} merupakan fungsi atas k , maka ϕ_{kk} disebut fungsi autokorelasi parsial (PACF).

2.4 Metode Autoregresive Integrated Moving Average (ARIMA)

2.4.1 Autoregresive (AR)

Autoregressive adalah model yang menggambarkan bahwa variabel *dependent* dipengaruhi oleh variabel *dependent* itu sendiri pada periode sebelumnya (Munawaroh, 2010). Pada model AR, nilai X_t ditunjukan sebagai suatu fungsi yang linier dari sejumlah X_t sebelumnya.

Bentuk umum dari model *Autoregresive* (AR) berorde p :

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \cdots + \phi_p X_{t-p} + \alpha \tag{2.9}$$

dimana:

- X_t : Variabel yang diramalkan
- X_{t-p} : Variabel yang menentukan
- ϕ_p : Koefisien komponen AR derajat ke- p
- α_t : Nilai kesalahan

Atau model AR dapat dituliskan sebagai:

$$\phi_p(B)X_t = \alpha_t \quad (2.10)$$

Dengan $\phi_p(B) = 1 - \phi_1B - \phi_2B^2 - \dots - \phi_pB^p$, dimana

B : Operator *backward* dimana $B^p X_t = X_{t-p}$

2.4.2 Moving Average (MA)

Moving Average (MA) merupakan suatu nilai saat ini sebagai jumlah pembobot dari *white noise* pada waktu sebelumnya atau nilai-nilai sebelumnya dari unsur kesalahan.

Bentuk umum dari model *Moving Average* (MA) berorde q :

$$X_t = \alpha_t - \theta_1\alpha - \theta_2\alpha - \dots - \theta_q\alpha \quad (2.11)$$

dimana:

- α_{t-q} : Nilai-nilai terdahulu dari kesalahan
- θ_q : Koefisien komponen MA derajat ke- q
- α_t : Nilai kesalahan saat t

Atau model MA dapat dituliskan sebagai:

$$X_t = \theta_q(B)\alpha_t \quad (2.12)$$

Dimana $\theta_q(B) = 1 - \theta_1B - \theta_2B^2 - \dots - \theta_qB^q$, dimana

B : Operator *backward* dimana $B^q \alpha_t = \alpha_{t-q}$

Hasil ramalan X_t dari Model MA didasarkan atas kombinasi linier dari kesalahan di waktu sebelumnya. Hal ini berbeda dengan model AR dimana X_t merupakan fungsi linier dari nilai sebenarnya pada waktu sebelumnya.

2.4.3 Autoregresive Moving Average (ARMA)

ARMA merupakan gabungan dari *Autoregresive* (AR) dan *Moving Average* (MA), dimana penggunaan gabungan kedua model, autokorelasinya dapat dipertimbangkan nilai dari masa-masa sebelumnya pada variabel yang diramalkan maupun nilai dari kesalahan dari waktu sebelumnya. Model AR dan MA dapat digabungkan dalam suatu persamaan. Gabungan dari model AR dan MA disebut ARMA (p,q) . Model umum dari ARMA (p,q) dapat ditulis sebagai berikut:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \cdots + \phi_p X_{t-p} + \alpha - \theta_1 \alpha_{t-1} - \cdots - \theta_q \alpha_{t-q} \quad (2.13)$$

2.4.4 Autoregresive Integrated Moving Average (ARIMA)

Pada kenyataanya, *time series* tidak selalu bersifat stasioner, sehingga perlu dilakukan pembeda (*differencing*) pada data aslinya agar data tersebut lebih mendekati atau bahkan bersifat stasioner. Pada model ARMA, jika ditambahkan non stasioner maka model umum dari ARIMA (p,d,q) akan terpenuhi. Model umum dari ARIMA (p,d,q) dapat dituliskan sebagai berikut:

$$\phi_p(B)(1 - B)^d X_t = \theta_q(B)\alpha_t \quad (2.14)$$

dimana:

d : tingkat pembeda agar proses menjadi stasioner

Persamaan (2.14) dapat dijabarkan dalam bentuk lain, yaitu:

$$\begin{aligned}
 (1 - \phi_1 B - \cdots - \phi_p B^p)(1 - B)^d X_t &= (1 - \theta_1 B - \cdots - \theta_q B^q) \alpha_t \\
 (X_t - \phi_1 B X_t - \cdots - \phi_p B^p X_t)(1 - B)^d &= (\alpha_t - \theta_1 B \alpha_t - \cdots - \theta_q B^q \alpha_t) \quad (2.15) \\
 (X_t - \phi_1 X_{t-1} - \cdots - \phi_p X_{t-p})(1 - B)^d &= (\alpha_t - \theta_1 \alpha_{t-1} - \cdots - \theta_q \alpha_{t-q})
 \end{aligned}$$

2.4.5 Seasonal Autoregressive Integrated Moving Average (SARIMA)

Jika model runtun waktu mempunyai pola Musiman, maka model ARIMA akan berubah menjadi model ARIMA Musiman atau biasa disebut dengan SARIMA (*Seasonal Autoregressive Integrated Moving Average*). Secara umum bentuk model ARIMA Musiman adalah ARIMA $(p, d, q)(P, D, Q)^S$ (Aswi & Sukarna, 2006).

dimana:

(p, d, q) : bagian yang tidak musiman dari model

(P, D, Q) : bagian musiman dari model

S : jumlah periode per musim

Untuk mendapatkan persamaan akhir ARIMA Musiman, sifat-sifat AR, MA, campuran ARMA atau campuran ARIMA harus terlihat jelas terpisahkan dengan satu musim penuh. Sebagai contoh, perhatikan suatu deret yang dikumpulkan per kuartal. Maka pembedaan musiman dapat dihitung sebagai berikut.

$$X'_t = X_t - \cdots X_{t-4} = (1 - B^4)X_t \quad (2.16)$$

Deret yang baru dinyatakan oleh X'_t , sekarang akan berhadapan dengan perbedaan antara satu kuartal dan data empat kuartal yang lalu. Angka yang tertera pada model menunjukkan bahwa data deret waktu mengalami musiman pada angka tersebut. Jika data yang dikumpulkan bulanan, perbedaan satu musim penuh (tahun) dapat dihitung sebagai berikut.

$$X'_t = X_t - X_{t-12} = (1 - B^{12})X_t \quad (2.17)$$

Secara aljabar adalah sederhana tetapi dapat berkepanjangan, oleh sebab itu untuk tujuan ilustrasi, kita ambil model umum ARIMA $(0,1,1)(0,1,1)^{12}$ sebagai berikut:

$$(1 - B)(1 - B^{12})X_t = (1 - \theta_1 B)(1 - \theta_1 B^{12})e_t \quad (2.18)$$

dimana:

$(1 - B)$: pembedaan pertama yang tidak musiman (*nonseasonal*)

$(1 - B^{12})$: pembedaan pertama yang musiman (*seasonal*)

$(1 - B^{12})$: MA (1) yang tidak musiman

$(1 - \theta_1 B^{12})$: MA (1) yang musiman

2.5 Tahap-tahap dalam ARIMA

2.5.1 Identifikasi Model

Hal pertama yang dilakukan dalam proses identifikasi adalah menguji apakah data stasioner atau belum. Jika data belum stasioner, maka perlu dilakukan *differencing* pada data. Untuk *differencing* pertama, maka nilai $d = 1$ dan seterusnya, tetapi jika data sudah stasioner tanpa dilakukan *differencing* maka nilai $d = 0$. Proses identifikasi model dilakukan dengan mengidentifikasi orde *Autoregresive*, *Moving Average* dan *Autoregresive Moving Average* pada grafik ACF dan PACF seperti tabel berikut:

Tabel 2.1 Pola Grafik ACF dan PACF

Proses	ACF	PACF
AR(p)	<i>Dies down</i> (menurun secara eksponensial)	<i>Cut off</i> (terputus) setelah $lag-p$
MA(q)	<i>Cut off</i> (terputus) setelah $lag-q$	<i>Dies down</i> (menurun secara eksponensial)
ARMA(p, q)	<i>Dies down</i> (menurun secara eksponensial) setelah $lag-(q-p)$	<i>Dies down</i> (menurun secara eksponensial) setelah $lag-(p-q)$

Sumber: (Wei, 2006)

2.5.2 Penaksiran Parameter

Setelah didapatkan model ARIMA (p, d, q) selanjutnya dilakukan penaksiran parameter. Penaksiran paramater dapat dilakukan menggunakan *Ordinary Least Square* atau menggunakan bantuan *software*.

2.5.3 Uji Signifikansi Model

Tahap ini dilakukan setelah berhasil mengestimasi nilai-nilai parameter dari model yang ditetapkan sementara untuk mengetahui apakah parameter signifikan atau tidak.

Berikut merupakan uji signifikansi parameter model pada parameter *Autoregressive*, yaitu:

$$H_0: \phi = 0 \quad (\text{parameter } \phi \text{ tidak signifikan dalam model})$$

$$H_1: \phi \neq 0 \quad (\text{parameter } \phi \text{ signifikan dalam model})$$

taraf signifikansi α

Kriteria keputusan: tolak H_0 jika $|t_{hitung}| > t_{\frac{\alpha}{2}, n-1}$ atau $P\text{-value} < \alpha$.

Dan untuk parameter *Moving Average*, yaitu:

$H_0: \theta = 0$ (parameter θ tidak signifikan dalam model)

$H_1: \theta \neq 0$ (parameter θ signifikan dalam model)

taraf signifikansi α

Kriteria keputusan: tolak H_0 jika $|t_{hitung}| > t_{\frac{\alpha}{2};n-1}$ atau $P\text{-value} < \alpha$

2.5.4 Peramalan

Peramalan merupakan suatu teknik untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data saat ini (Aswi, dan Sukarna, 2006). Tujuan dalam analisis *time series* adalah untuk meramalkan nilai masa depan (Wei, 2006). Dan tujuan peramalan untuk menghasilkan ramalan optimum yang tidak memiliki *error* atau *error* yang sangat kecil.

Berdasarkan pendapat di atas, peramalan merupakan suatu perkiraan mengenai peristiwa dimasa mendatang, sedangkan ramalan merupakan hasil perkiraan peramalan yang diperoleh. Dalam menaksir peristiwa mendatang, diperlukan suatu data, yaitu data dimasa lampau, data dimasa sekarang dan data dimasa mendatang.

2.6 Radial Basis Function Neural Network (RBFNN)

Model RBFNN terdiri atas 3 lapisan, yaitu lapisan *input*, lapisan *hidden* dan lapisan *output*. Vektor *input* x yang diterima di lapisan *input* akan dibawah ke lapisan *hidden* untuk diproses secara nonliner dengan fungsi aktivasi. Lapisan *hidden* akan menghasilkan *output* yang akan diproses di lapisan *output* secara linier (Wei *et al.*, 2011).

RBFNN menggunakan fungsi basis sebagai fungsi aktivasi pada lapisan

tersembunyi untuk setiap *neuron*. Adapun fungsi basis yang paling banyak digunakan adalah (Artaberi, 2016):

1. Fungsi multikuadratik

$$\psi(x, c_j) = ((x - c_j)^2 + \sigma^2)^{\frac{1}{2}} \quad (2.19)$$

2. Fungsi invers multikuadratik

$$\psi(x, c_j) = \frac{1}{((x - c_j^2)^2 + \sigma^2)^{\frac{1}{2}}} \quad (2.20)$$

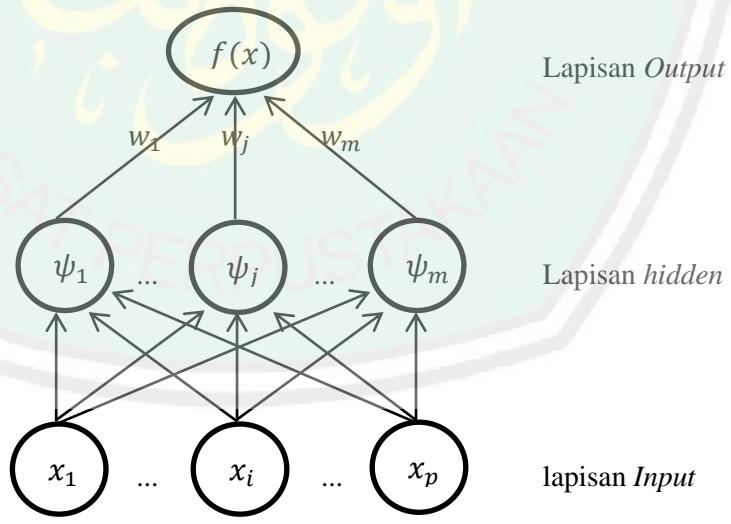
3. Fungsi Gaussian

$$\psi(x, c_j) = e^{\left(\frac{(x - c_j)^2}{2\sigma^2}\right)} \quad (2.21)$$

Dimana σ^2 adalah varian dari c , dengan $c = (c_1, c_2, \dots, c_m)$ dan $\sigma^2 \neq 0$

2.7 Arsitektur RBFNN

Arsitektur RBFNN dapat dilihat di gambar 2.1, sebagai berikut:



Gambar 2.1 Arsitektur RBFNN

Pada gambar 2.1 terdapat p komponen vektor *input* x , m buah fungsi basis dan 1 *output*. *Output* yang dihasilkan oleh RBFNN merupakan kombinasi linier dari

bobot $\{w_j\}_{j=1}^m$ dengan fungsi aktivasi $\psi_j(x, c_j)$. Sehingga model RBFNN dapat dirumuskan sebagai berikut:

$$f(x) = \sum_{j=1}^m w_j \psi_j(x, c_j) \quad (2.22)$$

Dengan

- m = banyak fungsi basis
- w_j = bobot *output* ke- j
- $\psi_j(x, c_j)$ = fungsi aktivasi *neuron* tersembunyi ke- j
- x = $[x_1 \ x_2 \ \dots \ x_p]$ vektor *input*

dari fungsi basis multikuadratik diperoleh suatu persamaan, sebagai berikut:

$$\begin{aligned} \psi_j(x, c_j) &= ((x - c_j)^2 + \sigma^2)^{\frac{1}{2}} \\ &= \left([(x_1 - c_1)^2 + (x_i - c_j)^2 + \dots + (x_p - c_m)^2] + \sigma^2 \right)^{\frac{1}{2}} \end{aligned} \quad (2.23)$$

Dengan

- x_i = variabel *input*
- c_j = pusat *neuron* tersembunyi
- σ_j = simpangan baku *neuron* tersembunyi

2.8 Fungsi Aktivasi

Fungsi aktivasi merupakan suatu fungsi dalam menentukan keluaran suatu *neuron*. Fungsi linier merupakan salah satu yang sering digunakan. Dalam fungsi linier nilai *output* akan sama dengan nilai *input* (Fausett, 1994). Dalam RBFNN fungsi aktivasi yang biasanya digunakan adalah fungsi multikuadratik.

2.9 Metode Pembelajaran dan Pelatihan

Proses pembelajaran merupakan salah satu bagian yang penting dalam konsep jaringan saraf. Proses pembelajaran bertujuan untuk melakukan pengaturan pada bobot jaringan saraf, sehingga didapatkan bobot yang sesuai dengan data yang dilatih. Ada 2 metode pembelajaran, yaitu metode pembelajaran terawasi dan metode pembelajaran tidak terawasi (Yeung *et al.*, 1998).

a. Pembelajaran terawasi

Pada proses ini, di lapisan *input* satu *input* telah diberikan pada satu *neuron* yang kemudian akan dijalankan sepanjang jaringan saraf hingga ke *neuron* pada lapisan *output*, hasil yang diperoleh akan dicocokkan dengan target, jika berbeda akan muncul *error*. Pembelajaran akan dilakukan lebih banyak jika diperoleh nilai *error* yang cukup besar.

b. Pembelajaran tidak terawasi

Pada proses ini, nilai bobot disusun dalam suatu interval yang tergantung dari nilai *input* yang diberikan. Tujuan dari pembelajaran ini untuk mengelompokkan unit-unit yang hampir sama satu area tertentu.

2.10 Ketepatan Model Peramalan

Ketepatan dipandang sebagai kriteria penolakan untuk memilih suatu metode peramalan dalam banyak situasi peramalan. Menurut Heizer dan Rendeer (2009), ada beberapa perhitungan yang biasa digunakan untuk membandingkan model peramalan yang berbeda, mengawasi peramalan, dan untuk memastikan peramalan berjalan dengan baik. Ukuran kesalahan yang digunakan diantaranya adalah:

1. *Mean Squared Error* (MSE)

$$MSE = \sum_{t=1}^n \frac{(A_t - F_t)^2}{n} \quad (2.24)$$

2. *Mean Absolute Error* (MAE)

$$MAE = \sum_{t=1}^n \frac{|A_t - F_t|}{n} \quad (2.25)$$

3. *Mean Absolute Percentage Error* (MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (2.26)$$

dimana:

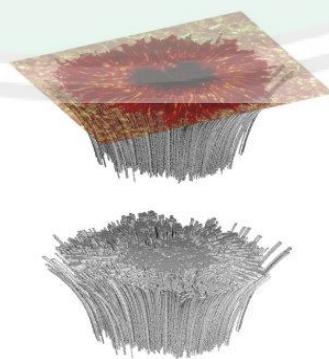
X_t : data aktual pada periode ke- t

F_t : data peramalan untuk periode ke- t

n : banyaknya data observasi

2.11 Bintik Matahari (*Sunspot*)

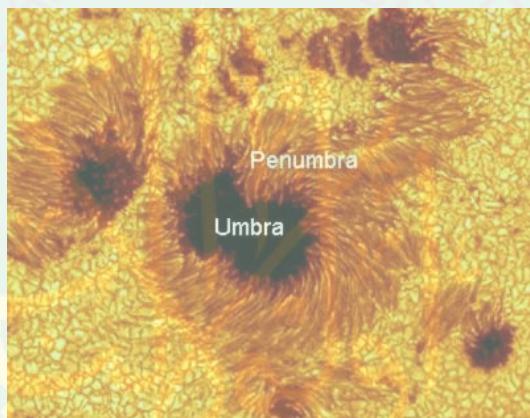
Bintik matahari (*sunspot*) adalah daerah gelap pada matahari dan terletak di lapisan fotosfer. *Sunspot* terlihat terang jelas (warna hitam) dan kontras karena adanya perbedaan suhu pada daerah *sunspot* dengan daerah di sekitarnya. Dalam tiga dimensi, *sunspot* digambarkan seperti gambar berikut:



Gambar 2.2 Bentuk *Sunspot* dalam Tiga Dimensi

Sunspot tampak gelap karena mempunyai suhu 4.000° K sampai dengan 4.500° K yang lebih rendah dari suhu fotosfer. Dengan adanya perbedaan temperatur tersebut, maka daerah yang mempunyai temperatur yang lebih rendah akan lebih sedikit mengeluarkan cahaya atau lebih gelap jika dibandingkan dengan permukaan matahari disekitarnya, sesuai dengan hukum *Stefan*.

Bintik hitam matahari dibagi menjadi dua bagian yaitu *umbra* dan *penumbra*. *Umbra* merupakan suatu bagian *sunspot* yang tampak lebih gelap dari sekitarnya. *Penumbra* merupakan batas dari suatu bintik dari tepi yang tidak teratur, selalu berubah-ubah, dan bulu yang bergetar-getar.



Gambar 2.3 *Umbra* pada Bagian Dalam dan *Penumbra* pada Bagian Luar

Temperatur *umbra* 4.000° K dan *penumbra* 4.500° K, sehingga tampak gelap dari bagian matahari yang lain. Hal ini disebabkan oleh aktivitas magnetik pada matahari (faktor kosmogenik) dari berbagai bukti empirik diduga kuat juga pengaruh terhadap variabilitas iklim jika dilihat dari kemiringan periodisitasnya dengan parameter iklim, yaitu sekitar 11 tahun. Dengan bertambahnya jumlah intensitas bintik berarti kondisi matahari semakin aktif dan bersesuaian keberadaannya dengan siklus 11 tahun yang mempresentasikan periode bintik dari minimum menuju maksimum dan kemudian kembali lagi keadaan minimum.

Akan tetapi panjang siklus tersebut tidaklah tepat 11 tahun, melainkan sekitar 9 sampai dengan 13 tahun. Untuk itu diperkenalkan parameter Panjang Siklus Matahari (PSB) yang menunjukkan perubahan jangka panjang aktivitas matahari, yang dihitung berdasarkan tahun (*epoch*) amplitudo minimum ke minimum atau maksimum ke maksimum dalam siklus bintik. Dari pengamatan siklus yang pendek menunjukkan aktivitas matahari tinggi, sedangkan siklus yang panjang menunjukkan bahwa tingkat aktivitas yang relatif lebih rendah (Setiahadi, 2001).

2.12 Bilangan *Sunspot*

Dalam pengamatan *sunspot*, indeks yang paling penting adalah *sunspot number* atau bilangan *sunspot*. Selama lebih dari 300 tahun, jumlah rata-rata *sunspot* secara teratur bervariasi dalam siklus 11 tahun. Setiap 11 tahun, polaritas medan magnet di Hemisfer matahari berubah. Jadi, siklus magnet matahari lengkap adalah 22 tahun.

Jumlah bilangan *sunspot* dapat dihitung berdasarkan perhitungan secara empiris dan tidak persis tepat keseluruhan diperlukan matahari (Hathaway, Wilson and Reichmann, 2002). R. Wolf merumuskan perhitungan jumlah bilangan *sunspot*, sebagai berikut:

$$R = K(10g + f) \quad (2.27)$$

Dimana

R : bilangan *sunspot*

K : faktor reduksi yang bergantung pada metode pengamatan dan teleskop yang digunakan

f : jumlah bilangan *sunspot* yang tampak di permukaan matahari

g : jumlah group *sunspot* yang tampak di permukaan matahari

2.13 Kajian Islam

2.13.1 Kajian Islam tentang Matahari

Matahari merupakan suatu bintang yang memproduksi cahaya dan panas yang cukup hebat karena adanya pembakaran di dalam matahari. Sebagaimana yang dijelaskan dalam QS an-Naba' ayat 12 dan 13 berikut ini:

وَبَنَيْنَا فَوْقَكُمْ سَبْعًا شِدَادًا ١٣ وَجَعَلْنَا سِرَاجًا وَهَاجًَا

Artinya:

“Dan Kami bina di atas kamu tujuh buah (langit) yang kokoh. Dan kami jadikan pelita yang amat terang (matahari)” (QS An-Naba' 78:12-13)

Selain itu di dalam al-Quran juga dijelaskan tentang fenomena yang ada di matahari yang berhubungan dengan orbit matahari. Ada 2 ayat yang berkaitan dengan orbit matahari, yaitu:

وَهُوَ الَّذِي خَلَقَ الْلَّيْلَ وَالنَّهَارَ وَالشَّمْسَ وَالْقَمَرَ كُلُّهُ فِي قَلَكٍ يَسْبِحُونَ ٢٣

Artinya:

“Dan Dialah yang telah menciptakan malam dan siang, matahari dan bulan. Masing-masing dari keduanya itu beredar di dalam garis edarnya” (QS Al-Anbiyya', 21:33).

لَا الشَّمْسُ يَنْبَغِي لَهَا أَنْ تُدْرِكَ الْقَمَرَ وَلَا الْلَّيْلُ سَابِقُ الْنَّهَارِ وَكُلُّهُ فِي قَلَكٍ يَسْبِحُونَ

Artinya:

“Tidaklah mungkin bagi matahari mendapatkan bulan dan malampun tidak dapat mendahului siang. Dan masing-masing beredar pada garis edarnya” (QS Yaasiin, 36: 40).

Adapun hadits shahih yang berkaitan tentang matahari, yaitu hadits Abu Dzarr Al Ghifari, yang berkata:

قال النبي صلى الله عليه وسلم لابي ذر حين غرب الشمس اتدرى اين تذهب قلت الله ورسوله اعلم قال فانها تذهب حتى تسجد تحت العرش فستأذن فيؤذن لها ويوشك أن تسجد فلا يقبل منها وستأذن فلا يؤذن لها يقال لها ارجعي من حيث جئت فتطلع من مغربها

Artinya:

"Nabi Saw berkata kepada Abu Dzarr ketika mathari terbenam: :Tahukah engkau kemana ia (matahari) pergi?" saya menjawab: "Allah dan Rasul-Nya lebih mengetahui." Nabi Menjawab: "sesungguhnya ia pergi bersujud di bawah 'Arsy meminta izin (kepada Allah) untuk terbit lalu ia diizinkan. Sudah hampir dekat waktunya dia bersujud namun tidak diterima sujudnya dan dia meminta izin namun tidak diizinkan. Lalu diperintahkan kepadanya: "kembalilah ke tempat dari mana engkau datang." Akhirnya terbitlah ia dari tempat terbenamnya (arah barat)." [HR Al Bukhari dan Muslim]

2.13.2 Kajian Islam Tentang Peramalan

Ilmu peramalan merupakan ilmu untuk menafsirkan kejadian yang akan datang atau terjadi, tetapi masih belum diketahui secara pasti. Peramalan merupakan ketrampilan dalam menilai atau menghitung dengan berpijak pada kejadian sebelumnya. Salah satu ayat al-Quran yang berkaitan dengan peramalan adalah surat Yusuf ayat 47-48 yang berkaitan dengan masalah perekonomian, sebagai berikut:

قال تَرْزَعُونَ سَبْعَ سِنِينَ دَأْبًا فَمَا حَصَدَتُمْ فَذَرُوهُ فِي سُنْبَلِهِ إِلَّا قَلِيلًا مِمَّا تَأْكُلُونَ ﴿٤٧﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ سَبْعُ شِدَادٌ يَأْكُلُنَّ مَا قَدَّمْتُمْ لَهُنَّ إِلَّا قَلِيلًا مِمَّا تَحْصِنُونَ ﴿٤٨﴾

Artinya:

"Yusuf berkata: "Supaya kamu bertanam tujuh tahun (lamanya) sebagaimana biasa: maka apa yang kamu tuai hendaklah kamu biarkan dibulirnya kecuali sedikit untuk kamu makan. Kemudian sesudah itu akan datang tujuh tahun yang amat sulit, yang menghabiskan apa yang kamu simpan untuk menghadapinya (tahun sulit), kecuali sedikit dari (bibit gandum) yang kamu simpan"" (QS Yusuf, 12: 47-48).

Peramalan yang dilakukan merupakan upaya untuk mencari pegangan dalam pengambilan keputusan, tetapi hasil dari perencanaan manusia dapat berubah tergantung dari upaya yang dilakukan untuk lebih baik. Apabila kita

mempersiapkan dengan baik maka hasilnya akan baik pula, dan apabila kita tidak mempersiapkan dengan baik maka hasilnya tidak baik pula, untuk itu kita harus berusaha untuk mendapatkan apa yang kita rencanakan. Dimana di dalam al-Quran telah dijelaskan dalam surat al-An'aam ayat 160, yaitu:

مَنْ جَاءَ بِالْحُسْنَةِ قَلْمَعٌ عَشْرُ أَمْتَالِهِ وَمَنْ جَاءَ بِالْسَّيْئَةِ فَلَا يُجْزَى إِلَّا مِثْلَهَا وَهُمْ لَا يُظْلَمُونَ ١٦٠

Artinya:

“Barangsiapa membawa amal yang baik, maka baginya (pahala) sepuluh kali lipat amalnya: dan barangsiapa yang membawa perbuatan jahat maka dia tidak diberi pembalasan melainkan seimbang dengan kejahatannya, sedang mereka sedikitpun tidak dianiaya (dirugikan)” (QS Al-An'aam, 6: 160).



BAB III

METODE PENELITIAN

3.1 Pendekatan Penelitian

Dalam penelitian ini pendekatan yang digunakan adalah pendekatan kuantitatif, yaitu suatu pendekatan penelitian yang menggunakan data berupa data numerik. Sedang jenis penelitiannya adalah penelitian deskriptif. Penelitian deskriptif adalah penelitian yang memberikan gambaran atau uraian atas suatu keadaan sejernih mungkin tanpa ada perlakuan terhadap obyek yang diteliti (Kuontur, 2004).

3.2 Identifikasi Variabel

Variabel yang digunakan dalam penelitian ini yaitu variabel X yang merupakan rata-rata bilangan *sunspot* setiap bulan selama dua siklus terhitung dari Januari 1987 sampai Desember 2016. Selain itu ada variabel Y yang merupakan data hasil *differencing* terhadap data asli, dimana $Y_t = X_t - X_{t-d}$. Adapun variabel x yaitu variabel yang terdiri dari $X_{t-1}, X_{t-2}, \dots, X_{t-12}$ dan variabel c yang merupakan pusat *neuron* tersembunyi.

3.3 Jenis dan Sumber Data

Sumber data yang digunakan adalah data sekunder, yaitu data yang sudah dikumpulkan oleh pihak BPAA LAPAN Pasuruan. Adapun jenis datanya adalah data runtut waktu (*time series*) karena secara kronologis data tersebut disusun berdasarkan waktu yang digunakan untuk melihat pengaruh perubahan dalam rentan waktu tertentu.

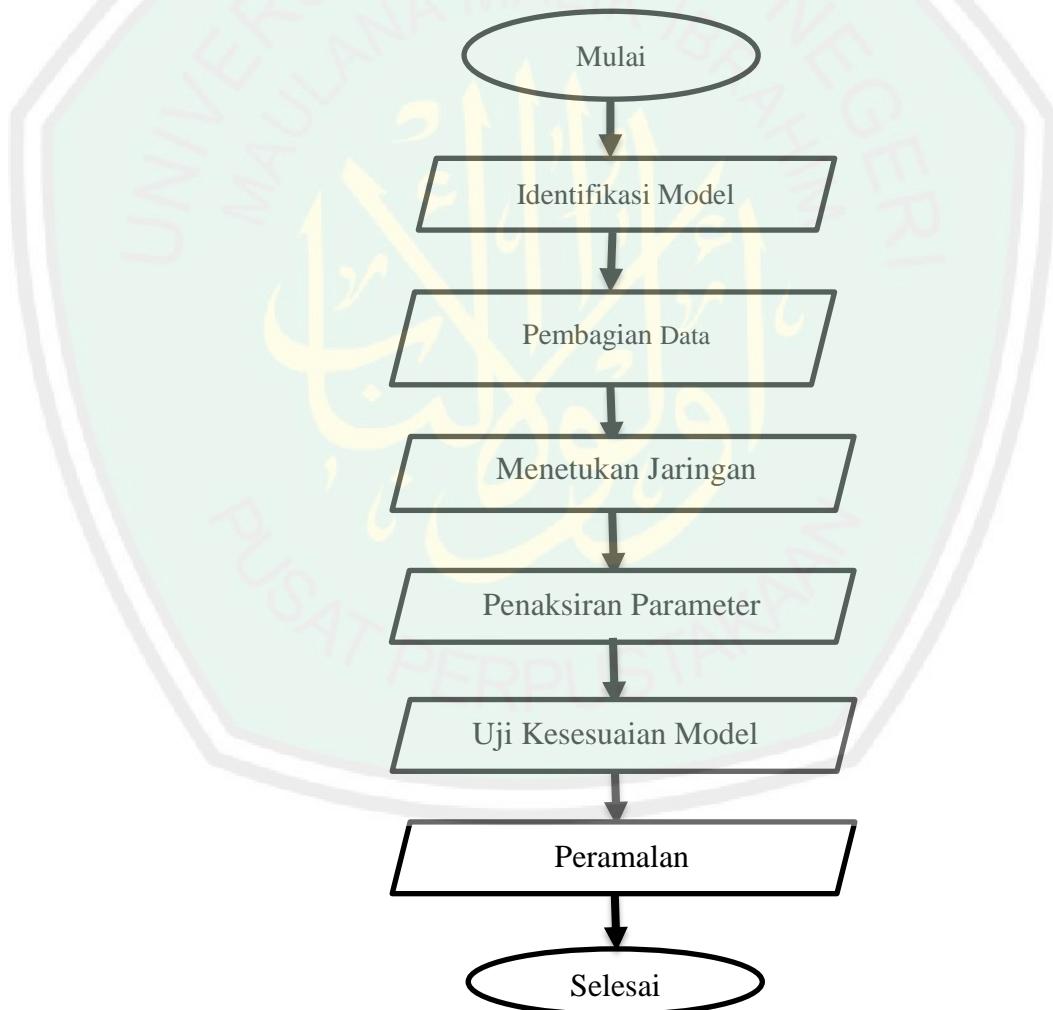
3.4 Metode Analisis

Setelah data yang diperlukan terkumpul, maka langkah selanjutnya adalah menganalisis data tersebut. Dalam analisis data, data akan diuji sampai layak digunakan. Untuk memudahkan proses perhitungan maka penulis menggunakan bantuan *software Minitab 16* dan *software Matlab 2015*.

3.5 Langkah-langkah Penelitian

3.5.1 Langkah-langkah RBF

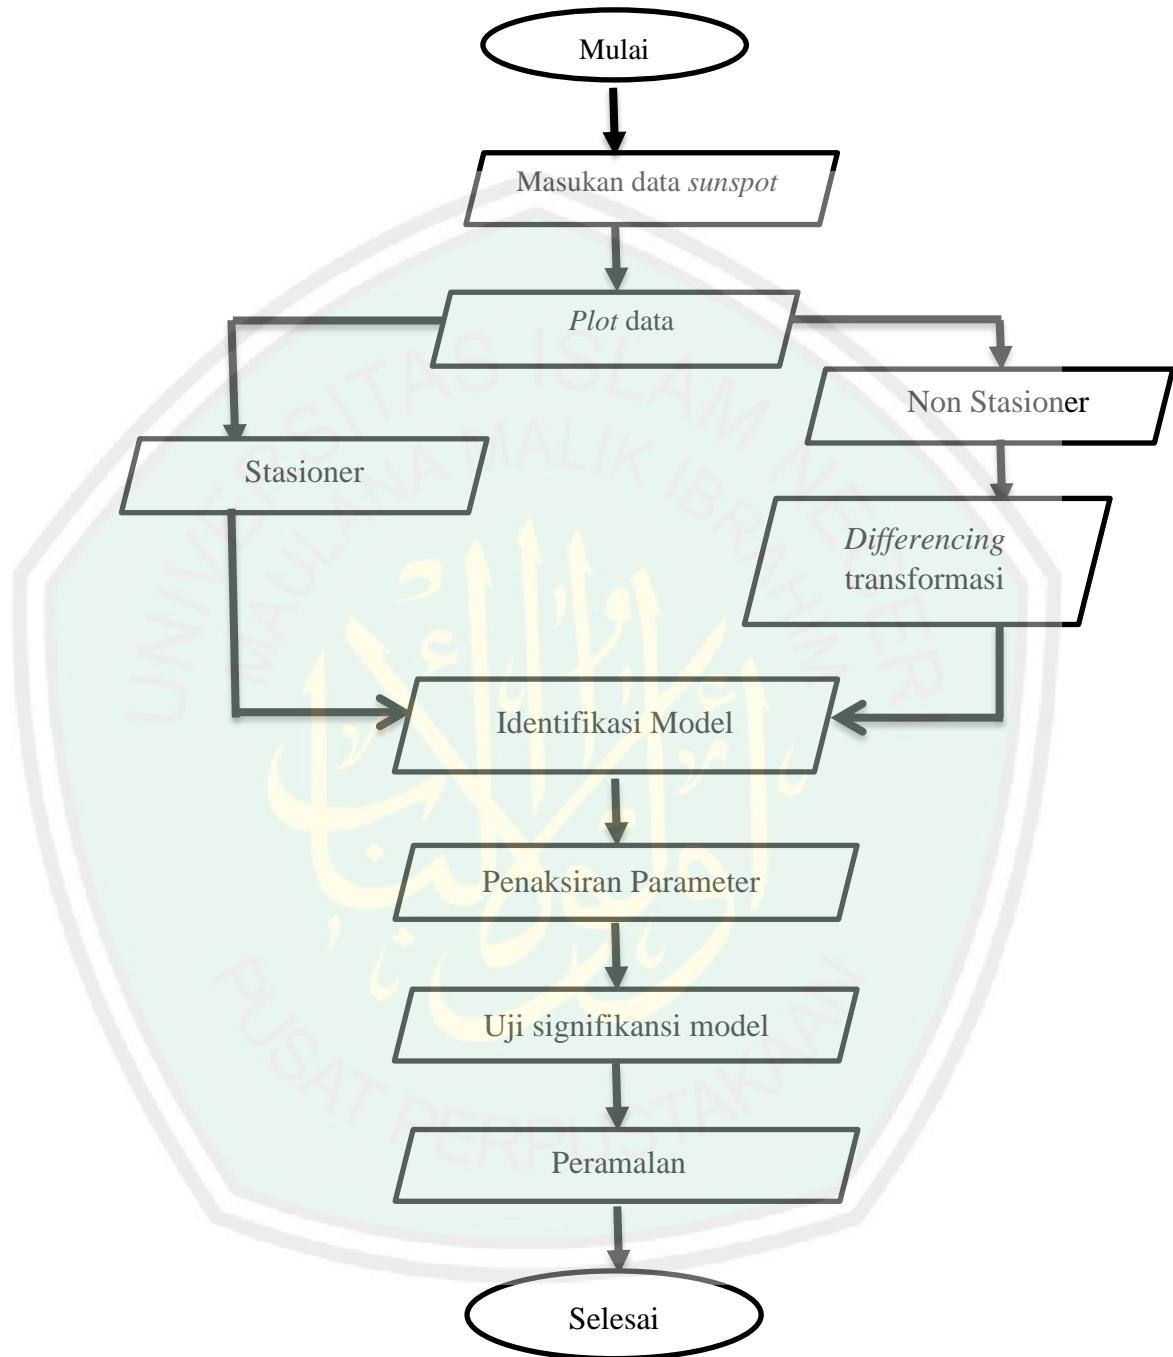
Langkah-langkah proses RBF adalah sebagai berikut:



Gambar 3.1 Flowchart Alur RBFNN

3.5.2 Langkah-langkah ARIMA

Langkah-langkah dalam proses ARIMA adalah sebagai berikut:



Gambar 3.2 Flowchart alur ARIMA

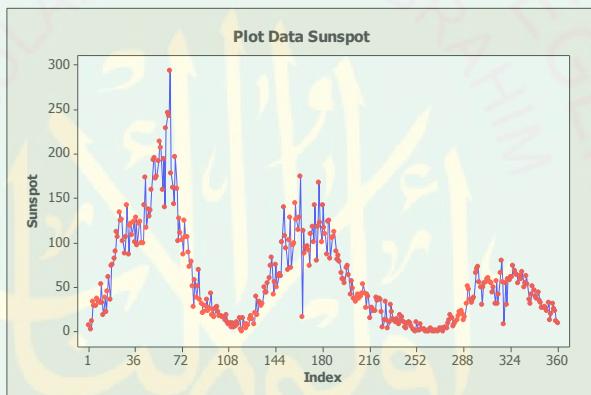
BAB IV

HASIL DAN PEMBAHASAN

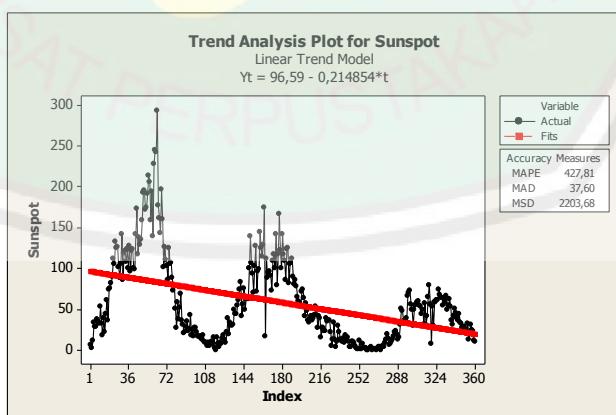
4.1 Peramalan dengan Model ARIMA

4.1.1 Plot Data Bilangan Sunspot

Sebelum melakukan peramalan pada deret waktu, langkah awal yang perlu dilakukan adalah membuat *plot* data. Hal ini digunakan untuk mengetahui pola data. Adapun *plot* yang terbentuk dari data bilangan *sunspot* (data dapat dilihat di lampiran 1) sebagai berikut:



Gambar 4.1 *Plot* Bulanan *Sunspot*

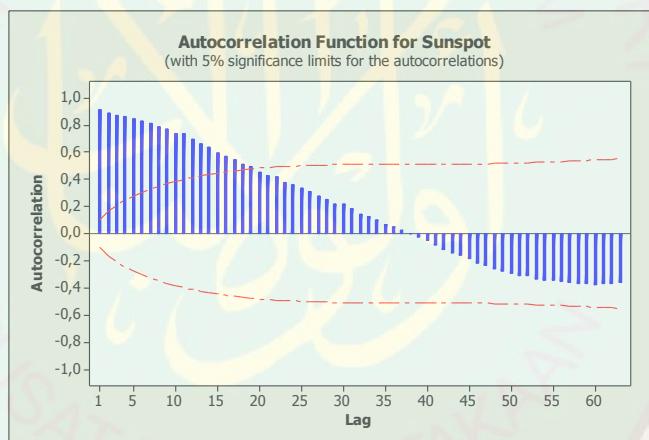


Gambar 4.2 *Plot* Data tehadap trend

Dari gambar 4.1 dan 4.2 terlihat grafik belum stasioner baik dalam rata-rata maupun varians, karena unsur trendnya masih terlihat dan terdapat pertumbuhan dan penurunan data, dimana data belum stabil pada nilai tengah dan variansnya, dengan kata lain fluktuasi data tidak berada di sekitar nilai rata-rata dan varians yang konstan serta terdapat pola berulang yang menunjukkan adanya pola musiman. Hal ini dikarenakan rata-rata dalam satu siklus matahari adalah 11 tahun, sehingga dalam kurun waktu ± 11 tahun akan terbentuk pola yang berulang.

4.1.2 Identifikasi Model

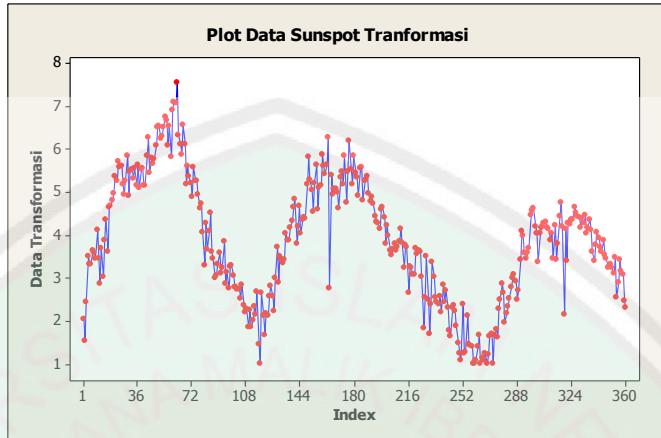
Untuk mengidentifikasi suatu model ARIMA pada data bilangan *sunspot* adalah dengan menghitung autokorelasi dan autokorelasi parsial dari data asli. Adapun *plot* autokorelasi dari data asli, sebagai berikut:



Gambar 4.3 *Plot* ACF data asli

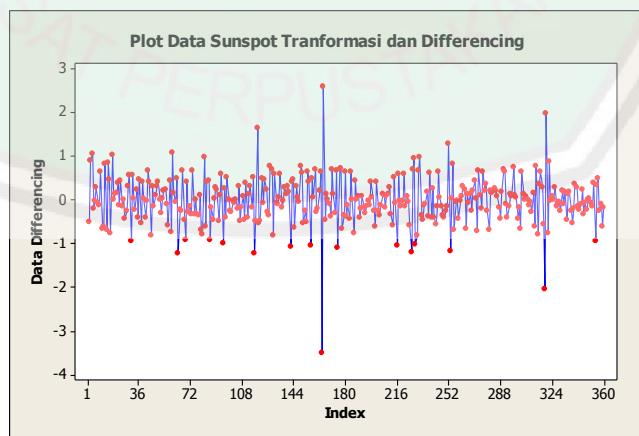
Dari gambar 4.3 terlihat bahwa terdapat 19 *lag* awal yang nilai ACF tidak mendekati nol dan secara nyata nilai ACFnya berada diluar selang r_k , hal ini menunjukan data bilangan *sunspot* belum stasioner. Untuk mencapai data yang stasioner perlu dilakukan transformasi agar data menjadi stasioner dalam varians. Dari hasil perhitungan transformasi *Box-Cox* didapatkan nilai *Rounded Value* = 0,36 seperti pada lampiran 2. Jika semua data bilangan *sunspot* dipangkatkan nilai

0,36 maka akan diperoleh nilai *Rounded Value* = 1,00 (lampiran 3) yang menunjukkan data sudah stasioner terhadap varians. Adapun hasil *plot* data bilangan *sunspot* seperti pada gambar berikut:



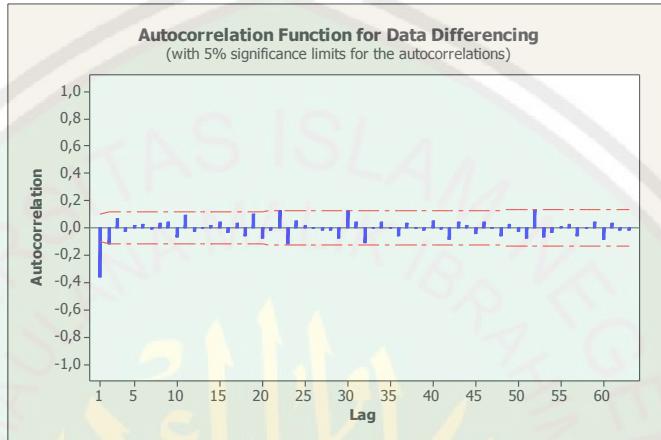
Gambar 4.4 *Plot* Data Transformasi

Dari gambar 4.4 terlihat data masih belum stasioner terhadap rata-rata meskipun sudah dilakukan transformasi. Karena transformasi belum dapat mengatasi kestasioneran dalam rata-rata maka perlu dilakukan *differencing* dari data asli yaitu dengan mengurangkan data sekarang dengan data satu periode sebelumnya, dan jumlah data menjadi $n - 1$. Adapun *plot* data hasil *differencing* pertama yang disajikan sebagai berikut:



Gambar 4.5 *Plot differencing*

Dari gambar 4.5 secara visual terlihat pola data sudah stasioner kecuali pada titik tertentu, karena data mulai stabil pada nilai tengah yang konstan. Setelah data *differencing* pertama diperoleh, maka selanjutnya dicari nilai ACFnya. Adapun *plot* ACF setelah di transformasi dan *differencing* pertama, sebagai berikut:



Gambar 4.6 Grafik ACF

Dari gambar 4.6 tampak bahwa nilai ACF berada pada sumbu horizontal sepanjang waktu seiring bertambahnya *lag* kecuali *lag* 1 yang berada diluar sumbu horizontal. Selain itu nilai ACF turun secara eksponensial pada selang r_k positif dan negatif secara bergantian sesudah *time lag* ke-1. Hal ini menunjukan bahwa data telah mencapai stasioner serta orde $d = 1$ karena hanya mengalami satu kali pembeda. Adapun nilai r_k dari populasi nilai ACF dapat dilakukan pengujian dengan selang kepercayaan 95% sebagai berikut:

$$n = 360$$

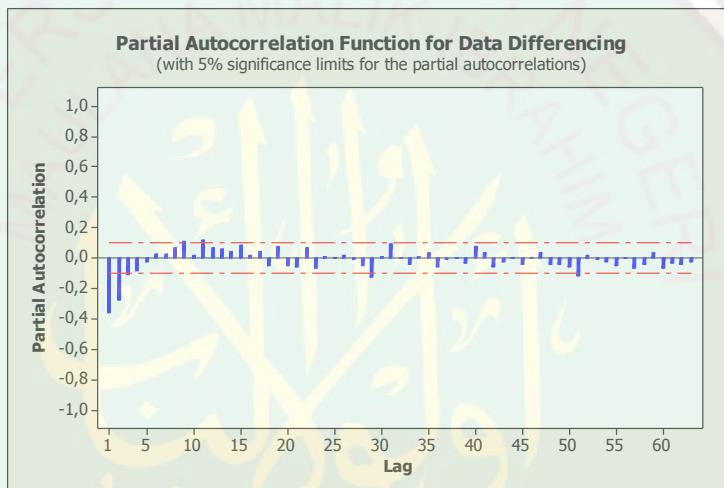
$$s_e r_k = \frac{1}{\sqrt{n}} = \frac{1}{\sqrt{360}} = 0,0527$$

$$-Z^{\frac{\alpha}{2}}(s_e r_k) \leq r_k \leq Z^{\frac{\alpha}{2}}(s_e r_k)$$

$$-1,961(0,0527) \leq r_k \leq 1,961(0,0527)$$

$$-0,10334 \leq r_k \leq 0,10334$$

Setelah dilakukan *differencing* pertama dipenuhi nilai r_k dengan batas $-0,10334 \leq r_k \leq 0,10334$ yang berarti bahwa 95% dari seluruh koefesien korelasi bernilai nol yang berarti data sudah bersifat acak, kecuali pada *lag* 1 dan karena pada *lag* ini nilai ACFnya berada diluar selang koefesien korelasi (r_k), akan tetapi tidak signifikan. Langkah selanjutnya adalah mencari model sementara, sehingga perlu dibuat *plot* Autokorelasi Parsial (PACF) untuk data yang sudah stasioner. Adapun *plot* PACF, sebagai berikut:



Gambar 4.7 Plot PACF

Dari model yang diusulkan dari pengujian koefesien ACF dan PACF, yaitu MA(1) dan AR(3) karena dari kedua koefesien nampak sempurna menurun menuju nol setelah *lag* ke-1 untuk ACF dan terdapat tiga *lag* yang keluar untuk PACF. Sementara untuk musimannya adalah 11 dengan SMA(1) dan SAR(1) Sehingga model yang dapat digunakan untuk meramalkan bilangan *sunsot* adalah ARIMA dengan $p = 3, d = 1, q = 1, P = 1, D = 1, Q = 1$ atau ARIMA $(3,1,1)(1,1,1)^{11}$ dengan model persamaan sebagai berikut:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \Phi Y_{t-11} + \alpha - \theta_1 \alpha_{t-1} - \Theta \alpha_{t-11}$$

Adapun alternatif model yang dapat digunakan, sebagai berikut:

ARIMA (3,1,1)(1,1,1)¹¹ ARIMA (2,1,1)(1,1,1)¹¹ ARIMA (1,1,1)(1,1,1)¹¹

ARIMA (0,1,1)(1,1,1)¹¹ ARIMA (3,1,0)(1,1,1)¹¹ ARIMA (2,1,0)(1,1,1)¹¹

ARIMA (1,1,0)(1,1,1)¹¹ ARIMA (3,1,1)(1,1,0)¹¹ ARIMA (2,1,1)(1,1,0)¹¹

ARIMA (1,1,1)(1,1,0)¹¹ ARIMA (0,1,1)(1,1,0)¹¹ ARIMA (3,1,0)(1,1,0)¹¹

ARIMA (2,1,0)(1,1,0)¹¹ ARIMA (1,1,0)(1,1,0)¹¹ ARIMA (3,1,1)(0,1,1)¹¹

ARIMA (2,1,1)(0,1,1)¹¹ ARIMA (1,1,1)(0,1,1)¹¹ ARIMA (0,1,1)(0,1,1)¹¹

ARIMA (3,1,0)(0,1,1)¹¹ ARIMA (2,1,0)(0,1,1)¹¹ ARIMA (1,1,0)(0,1,1)¹¹

4.1.3 Pendugaan Parameter

Sebelum melakukan pendugaan parameter, langkah selanjutnya adalah memilih model terbaik. Model yang baik memiliki parameter yang signifikan dimana nilai $p - value$ dari statistik uji kurang dari nilai $\alpha(0,05)$. Adapun hasil signifikan untuk beberapa model melalui bantuan *software Minitab* seperti tertera pada tabel, sebagai berikut:

Tabel 4.1 Uji Signifikansi Parameter

Model	Parameter	Konstanta	$p - value$	Ket
ARIMA (3,1,1)(1,1,1) ¹¹	AR (1)	-1,4342	0,000	Signifikan
	AR (2)	-0,6842	0,000	Signifikan
	AR (3)	-0,2068	0,000	Signifikan
	SAR (1)	0,1321	0,025	Signifikan
	MA (1)	-0,9447	0,000	Signifikan
	SMA (1)	0,9566	0,000	Signifikan
ARIMA (2,1,1)(1,1,1) ¹¹	AR (1)	-0,0319	0,846	Tidak Signifikan
	AR (2)	-0,0477	0,620	Tidak Signifikan
	SAR (1)	0,1528	0,008	Signifikan
	MA (1)	0,4948	0,002	Signifikan
	SMA (1)	0,9568	0,000	Signifikan
ARIMA	AR (1)	0,40141	0,890	Tidak Signifikan

(1,1,1)(1,1,1) ¹¹	SAR (1)	0,1546	0,007	Signifikan
	MA (1)	0,5437	0,000	Signifikan
	SMA (1)	0,9584	0,000	Signifikan
ARIMA (0,1,1)(1,1,1) ¹¹	SAR (1)	0,1541	0,007	Signifikan
	MA (1)	0,5344	0,000	Signifikan
	SMA (1)	0,9585	0,000	Signifikan
ARIMA (3,1,0)(1,1,1) ¹¹	AR (1)	-0,5160	0,000	Signifikan
	AR (2)	-0,2825	0,000	Signifikan
	AR (3)	-0,1277	0,017	Signifikan
	SAR (1)	0,1498	0,009	Signifikan
	SMA (1)	0,9586	0,000	Signifikan
ARIMA (2,1,0)(1,1,1) ¹¹	AR (1)	-0,4885	0,000	Signifikan
	AR (2)	-0,2195	0,000	Signifikan
	SAR (1)	0,1349	0,019	Signifikan
	SMA (1)	0,9574	0,000	Signifikan
ARIMA (1,1,0)(1,1,1) ¹¹	AR (1)	-0,4015	0,000	Signifikan
	SAR (1)	0,1322	0,021	Signifikan
	SMA (1)	0,9592	0,000	Signifikan
ARIMA (3,1,1)(1,1,0) ¹¹	AR (1)	ERROR	ERROR	-
	AR (2)			
	AR (3)			
	SAR (1)			
	MA (1)			
ARIMA (2,1,1)(1,1,0) ¹¹	AR (1)	0,0600	0,706	Tidak Signifikan
	AR (2)	-0,0012	0,990	Tidak Signifikan
	SAR (1)	-0,4561	0,000	Signifikan
	MA (1)	0,5647	0,000	Signifikan
ARIMA (1,1,1)(1,1,0) ¹¹	AR (1)	0,0624	0,546	Tidak Signifikan
	SAR (1)	-0,4560	0,000	Signifikan
	MA (1)	0,5671	0,000	Signifikan
ARIMA (0,1,1)(1,1,0) ¹¹	SAR (1)	-0,4561	0,000	Signifikan
	MA (1)	0,5245	0,000	Signifikan
ARIMA (3,1,0)(1,1,0) ¹¹	AR (1)	-0,4885	0,000	Signifikan
	AR (2)	-0,2537	0,000	Signifikan

	AR (3)	-0,1543	0,004	Signifikan
	SAR (1)	-0,4592	0,000	Signifikan
ARIMA $(2,1,0)(1,1,0)^{11}$	AR (1)	-0,4603	0,000	Signifikan
	AR (2)	-0,1825	0,001	Tidak Signifikan
	SAR (1)	-0,4635	0,000	Signifikan
ARIMA $(1,1,0)(1,1,0)^{11}$	AR (1)	-0,3894	0,000	Signifikan
	SAR (1)	-0,4762	0,000	Signifikan
ARIMA $(3,1,1)(0,1,1)^{11}$	AR (1)	-1,4972	0,000	Signifikan
	AR (2)	-0,7259	0,000	Signifikan
	AR (3)	-0,2099	0,000	Signifikan
	MA (1)	-0,9827	0,000	Signifikan
	SMA (1)	0,9544	0,000	Signifikan
ARIMA $(2,1,1)(0,1,1)^{11}$	AR (1)	-0,0653	0,711	Tidak Signifikan
	AR (2)	-0,0549	0,583	Tidak Signifikan
	MA (1)	0,4571	0,007	Signifikan
	SMA (1)	0,9559	0,000	Signifikan
ARIMA $(1,1,1)(0,1,1)^{11}$	AR (1)	-0,0018	0,986	Tidak Signifikan
	MA (1)	0,5207	0,000	Signifikan
	SMA (1)	0,9548	0,000	Signifikan
ARIMA $(0,1,1)(0,1,1)^{11}$	MA (1)	0,5219	0,000	Signifikan
	SMA (1)	0,9548	0,000	Signifikan
ARIMA $(3,1,0)(0,1,1)^{11}$	AR (1)	-0,5130	0,000	Signifikan
	AR (2)	-0,2707	0,000	Signifikan
	AR (3)	-0,1084	0,043	Signifikan
	SMA (1)	0,9623	0,000	Signifikan
ARIMA $(2,1,0)(0,1,1)^{11}$	AR (1)	-0,4893	0,000	Signifikan
	AR (2)	-0,2172	0,000	Signifikan
	SMA (1)	0,9623	0,000	Signifikan
ARIMA $(1,1,0)(0,1,1)^{11}$	AR (1)	-0,4020	0,000	Signifikan
	SMA (1)	0,9622	0,000	Signifikan

Diperoleh beberapa 13 model yang signifikan yaitu ARIMA $(3,1,1)(1,1,1)^{11}$, ARIMA $(0,1,1)(1,1,1)^{11}$, ARIMA $(3,1,0)(1,1,1)^{11}$, ARIMA $(2,1,0)(1,1,1)^{11}$,

ARIMA $(1,1,0)(1,1,1)^{11}$, ARIMA $(0,1,1)(1,1,0)^{11}$, ARIMA $(3,1,0)(1,1,0)^{11}$, ARIMA $(1,1,0)(1,1,0)^{11}$, ARIMA $(3,1,1)(0,1,1)^{11}$, ARIMA $(0,1,1)(0,1,1)^{11}$, ARIMA $(3,1,0)(0,1,1)^{11}$, ARIMA $(2,1,0)(0,1,1)^{11}$, ARIMA $(1,1,0)(0,1,1)^{11}$. Selanjutnya akan di uji kelayakan model dan dipilih model terbaik.

4.1.4 Uji Kesesuaian Model

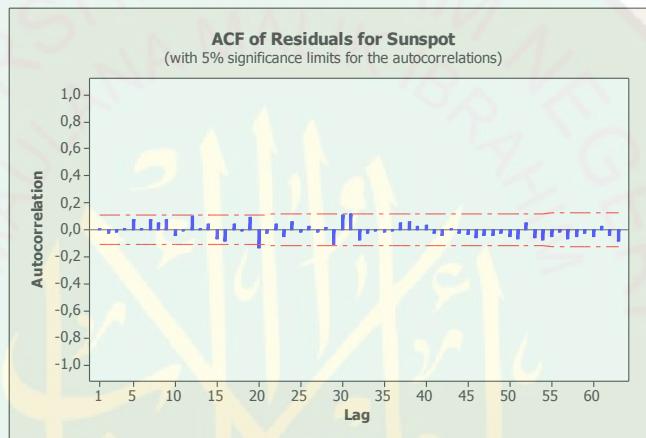
Sebelum model digunakan dalam peramalan, perlu dilakukan pengujian kelayakan parameter dari model tersebut. Keputusan dapat diambil berdasarkan nilai $p - value$ atau statistik uji Q dengan H_0 adalah model layak digunakan. Model dikatakan layak jika $Q \leq \chi^2_{k-p-q}$, dimana k adalah *lag* maksimum, p adalah ordo AR, q adalah ordo MA atau $p - value$ dari statistik uji Q lebih besar dari $\alpha(0,05)$. Hasil pemeriksaan nilai $p - value$ dari uji Q dapat dilihat pada tabel, sebagai berikut:

Tabel 4.2 Nilai $p - value$ dari uji Q

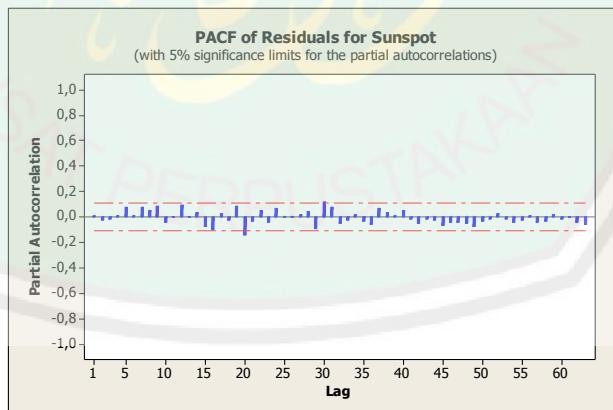
Model	<i>p-value</i> L-Jung Box				Keputusan
	Lag 12	Lag 24	Lag 36	Lag 48	
ARIMA $(3,1,1)(1,1,1)^{11}$	0,004	0,003	0,002	0,022	Belum <i>white noise</i>
ARIMA $(0,1,1)(1,1,1)^{11}$	0,185	0,067	0,038	0,124	<i>white noise</i>
ARIMA $(3,1,0)(1,1,1)^{11}$	0,052	0,016	0,012	0,060	Belum <i>white noise</i>
ARIMA $(2,1,0)(1,1,1)^{11}$	0,016	0,006	0,003	0,033	Belum <i>white noise</i>
ARIMA $(1,1,0)(1,1,1)^{11}$	0,000	0,000	0,000	0,001	Belum <i>white noise</i>
ARIMA $(0,1,1)(1,1,0)^{11}$	0,000	0,000	0,000	0,000	Belum <i>white noise</i>
ARIMA $(3,1,0)(1,1,0)^{11}$	0,001	0,000	0,000	0,000	Belum <i>white noise</i>
ARIMA $(1,1,0)(1,1,0)^{11}$	0,000	0,000	0,000	0,000	Belum <i>white noise</i>
ARIMA $(3,1,1)(0,1,1)^{11}$	0,002	0,002	0,002	0,023	Belum <i>white noise</i>
ARIMA $(0,1,1)(0,1,1)^{11}$	0,038	0,021	0,015	0,075	Belum <i>white noise</i>
ARIMA $(3,1,0)(0,1,1)^{11}$	0,011	0,005	0,005	0,044	Belum <i>white noise</i>

ARIMA (2,1,0)(0,1,1) ¹¹	0,008	0,004	0,003	0,039	Belum <i>white noise</i>
ARIMA (1,1,0)(0,1,1) ¹¹	0,000	0,000	0,000	0,000	Belum <i>white noise</i>

Dari tabel 4.2 di atas diperoleh hasil pengujian model, dimana model ARIMA (0,1,1)(1,1,1)¹¹ memenuhi asumsi *white noise* karena nilai $p - value$ lebih dari $\alpha = 0,05$ kecuali pada *lag* 36. Selanjutnya akan dilakukan uji asumsi residual, adapun *plot* ACF dan PACF dari residualnya untuk ARIMA (0,1,1)(1,1,1)¹¹, sebagai berikut:



Gambar 4.8 *Plot* ACF Residual



Gambar 4.9 *Plot* PACF Residual

Pada gambar 4.8 dan gambar 4.9 menunjukkan bahwa tidak ada *lag* yang keluar melebihi garis kepercayaan kecuali *lag* 20 pada ACF dan PACF tetapi tidak signifikan. Hal ini menunjukkan tidak ada *lag* yang signifikan yang artinya *error*

bersifat acak atau *white noise* terpenuhi. Oleh sebab itu, model ARIMA $(0,1,1)(1,1,1)^{11}$ ¹¹ dapat digunakan.

4.1.5 Peramalan ARIMA

Setelah didapatkan model ARIMA $(0,1,1)(1,1,1)^{11}$ dengan parameter telah signifikan. Selanjutnya akan dilakukan peramalan menggunakan model ARIMA $(0,1,1)(1,1,1)^{11}$, adapun persamaan yang diperoleh:

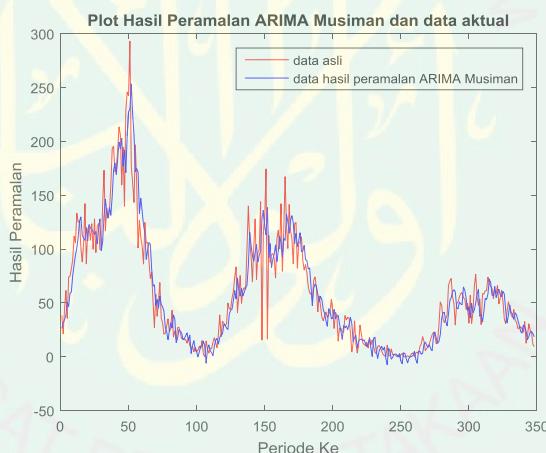
$$Y_t = \phi_0 + \Phi Y_{t-11} - \theta_1 \alpha_{t-1} - \Theta \alpha_{t-11}$$

$$X_t - X_{t-1} = \phi_0 + \Phi(X_{t-11} - X_{t-12}) - \theta_1 \alpha_{t-1} - \Theta \alpha_{t-11}$$

$$X_t = X_{t-1} + \phi_0 + \Phi X_{t-11} - \Phi X_{t-12} - \theta \alpha_{t-1} - \Theta \alpha_{t-11}$$

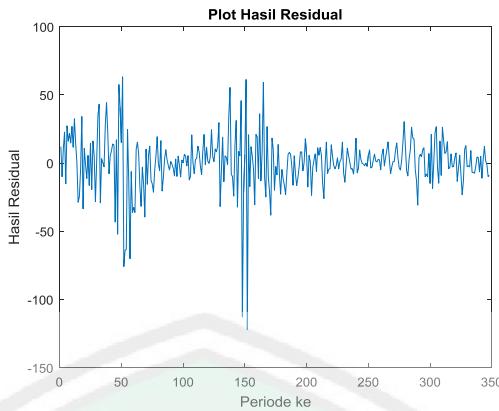
$$X_t = X_{t-1} - 0,0497 + 0,1541X_{t-11} - 0,1541X_{t-12} - 0,5344\alpha_{t-1} - 0,9585\alpha_{t-11}$$

Diperoleh *plot* dari data asli dengan hasil peramalan:



Gambar 4.10 *Plot* Data Asli dan Peramalan

Adapun *plot* hasil residual dari data aktual dengan hasil peramalan, sebagai berikut:



Gambar 4.11 Plot Hasil Residual

Dari gambar 4.11 terlihat bahwa pada periode tertentu hasil peramalan dengan data aktual berbeda cukup jauh. Sedangkan hasil *error* yang diperoleh, seperti pada tabel 4.3:

Tabel 4.3 Hasil *error* ARIMA setiap siklus

Periode	Siklus ke	Error (%)
Jan (1987) – Okt (1996)	22	40%
Nov (1997) – Ags (2008)	23	49%
Sep (2008) – Des (2016)	24	53%

Dari tabel 4.3 di atas terlihat pada siklus ke 22 hasil *error* yang diperoleh mencapai 40% sedangkan pada siklus ke 23 mencapai 49% dan pada siklus ke 24 mencapai 53%. Hal ini menunjukkan *error* dari ARIMA semakin meningkat seiring berubahnya siklus.

Berdasarkan model yang telah diajukan, maka dapat diartikan bahwa peramalan jumlah bilangan *sunspot* bergantung pada data periode sebelumnya yang ditambahkan konstanta sebesar 0,0497, bertambah 0,1541 dari data 11 periode sebelumnya dan berkurang 0,1541 dari data 12 periode sebelumnya dan dikurangi 0,5344 kali residual periode sebelumnya dan berkurang 0,9585 dari data residual 11 periode sebelumnya. Jika data sebelumnya 9,38 serta residual 11

periode sebelumnya sebesar 4,38 dan residual periode sebelumnya -9,12 serta data 11 periode sebelumnya 27,86 dan data 12 periode sebelumnya sebesar 26,75, maka jumlah bilangan *sunspot* untuk Januari 2017 (periode 133) adalah:

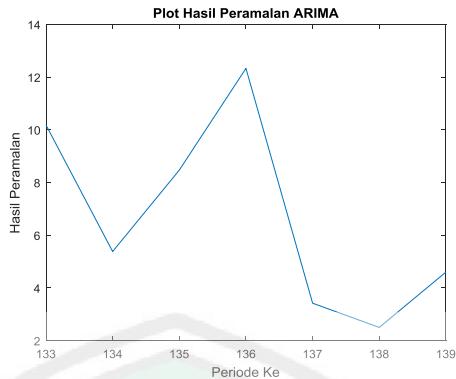
$$\begin{aligned}
 X_t &= 9,38 - 0,0497 + 0,1541(27,86) - 0,1541(26,75) - 0,5344(-9,12) \\
 &\quad - 0,9585(4,38) \\
 &= 10,18
 \end{aligned}$$

Untuk bulan-bulan berikutnya juga dapat dihitung seperti model ramalan pada bulan januari di atas. Adapun hasil perhitungan ramalan sampai bulan Juli 2017 seperti pada tabel berikut:

Tabel 4.4 Hasil Peramalan ARIMA

Periode	Hasil Peramalan
133	10,18
134	5,38
135	8,47
136	12,33
137	3,42
138	2,50
139	4,60

Adapun *plot* hasil ramalan, sebagai berikut:



Gambar 4.12 Plot Hasil Peramalan ARIMA

Grafik di atas menjelaskan bahwa jumlah bilangan *sunspot* mengalami penurunan dari periode 133 sampai 134 tetapi meningkat pada periode 135 dan 136 kemudian turun lagi pada periode 137 dan 138 dan meningkat pada periode 139. Tetapi perubahan yang terjadi tidak signifikan hal ini terjadi karena kondisi matahari memasuki periode akhir dan masuk ke periode terbaru. Sedangkan, analisis kesalahan sebagai berikut:

$$SSE = \sum_{t=1}^n (X_t - F_t)^2$$

$$= 7,9417 \times 10^2$$

$$MSE = \frac{1}{n} \sum_{t=1}^n (X_t - F_t)^2$$

$$= 1,1345 \times 10^2$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|X_t - F_t|}{X_t} 100\%$$

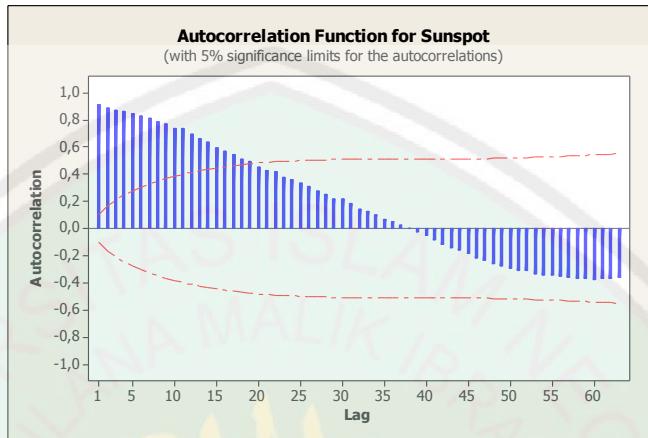
$$= 56,9\%$$

Didapatkan nilai dari MSE adalah $1,1345 \times 10^2$ dengan MAPE sebesar 56,9%.

4.2 Peramalan dengan RBFNN

4.2.1 Identifikasi Model

Berikut adalah *plot ACF* data jumlah bilangan *sunspot* untuk melihat *lag-lag* yang signifikan.



Gambar 4.13 *Plot ACF* data asli

Berdasarkan gambar 4.13, menunjukkan *lag* yang signifikan terletak pada *lag* 1 sampai *lag* 19. Dengan demikian diperoleh 19 variabel *input* yaitu x_{t-1} sampai x_{t-19} .

4.2.2 Pembagian Data

Data bulanan *sunspot* dibagi menjadi dua bagian yaitu data *training* dan data *testing*. Pada skripsi ini data akan digunakan sebagai data *training* saja, sehingga komposisi yang digunakan adalah 100% untuk data *training* dan 0% untuk data *testing*.

4.2.3 Menentukan Jaringan Optimum

Setelah diperoleh 19 *inputan*, selanjutnya akan ditentukan banyak *neuron* tersembunyi. Adapun hasilnya dapat dilihat pada tabel berikut:

Tabel 4.5 Hasil SSE dan MAPE dari *neuron* tersembunyi

Banyak <i>neuron</i>	SSE
2 <i>neuron</i>	$2,2587 \times 10^5$
3 <i>neuron</i>	$2,2235 \times 10^5$
4 <i>neuron</i>	$2,1971 \times 10^5$
5 <i>neuron</i>	$2,1572 \times 10^5$
6 <i>neuron</i>	$1,6794 \times 10^5$
7 <i>neuron</i>	$1,5528 \times 10^5$
8 <i>neuron</i>	$1,5466 \times 10^5$
9 <i>neuron</i>	$1,4195 \times 10^5$
10 <i>neuron</i>	$1,3536 \times 10^5$

Pada tabel 4.5 di atas terlihat bahwa nilai SSE terkecil terletak pada 10 *neuron*. Sehingga model RBFNN yang digunakan dalam peramalan mempunyai jaringan arsitektur 19 *input* dan 10 *neuron* pada lapisan tersembunyi.

4.2.4 Penaksiran Parameter

Jaringan arsitektur yang digunakan yaitu: 19 *input*, 10 *neuron* tersembunyi dan 1 *output* sehingga untuk data di atas $x = (x_1, x_2, \dots, x_{120})$:

$$w_0 + w_1\psi(x_1, c_1) + w_2\psi(x_1, c_2) + \dots + w_{10}\psi(x_1, c_{10}) = y_1$$

$$w_0 + w_1\psi(x_2, c_1) + w_2\psi(x_2, c_2) + \dots + w_{10}\psi(x_2, c_{10}) = y_2$$

⋮

$$w_0 + w_1\psi(x_{340}, c_1) + w_2\psi(x_{340}, c_2) + \dots + w_{10}\psi(x_{340}, c_{10}) = y_{340}$$

Diperoleh persamaan matrix untuk data *training*:

$$\begin{bmatrix} 1 & \psi(x_1, c_1) & \dots & \psi(x_1, c_{10}) \\ 1 & \psi(x_2, c_1) & \dots & \psi(x_2, c_{10}) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \psi(x_{340}, c_1) & \dots & \psi(x_{340}, c_{10}) \end{bmatrix} \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{10} \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{340} \end{bmatrix}$$

Dengan pembagian data x sebagai berikut:

Tabel 4.6 Pembagian data x

	X_{t-1}	X_{t-2}	...	X_{t-19}
x_1	74,86	73,89	...	6,47
x_2	96,84	127,92	...	81,72
:				
x_{340}	11,67	22,28	...	50,92

Data y :Tabel 4.7 Data y

y_1	81,72
y_2	90,23
:	:
y_{340}	9,38

Perhitungan $\psi_j(x_i, c_j)$, dengan c_j sesuai lampiran 4, adapun fungsi basis yang digunakan yaitu, Fungsi Multikuadratik

$$\psi(x, c_j) = ((x - c_j)^2 + \sigma^2)^{\frac{1}{2}}$$

Adapun nilai dari fungsi basis sebagai berikut:

$$\begin{aligned}
 \psi_1(x_1, c_1) &= ((x_1 - c_1)^2 + \sigma^2)^{\frac{1}{2}} \\
 &= ([(X_{t-1} - c_1)^2 + (X_{t-2} - c_1)^2 + \cdots + (X_{t-19} - c_1)^2] + \sigma^2)^{\frac{1}{2}} \\
 &=([(74,68 - 74,68)^2 + (73,89 - 73,89)^2 + \cdots + (6,47 - 6,47)^2] \\
 &\quad + 35,07)^{\frac{1}{2}} \\
 &= 5,91
 \end{aligned}$$

⋮

$$\begin{aligned}
 \psi_8(x_1, c_8) &= ((x_1 - c_8)^2 + \sigma^2)^{\frac{1}{2}} \\
 &= ([(X_{t-1} - c_8)^2 + (X_{t-2} - c_8)^2 + \cdots + (X_{t-12} - c_8)^2] + \sigma^2)^{\frac{1}{2}} \\
 &=([(74,68 - 11,67)^2 + (73,89 - 22,69)^2 + \cdots + (6,47 - 50,92)^2] \\
 &\quad + 29,76)^{\frac{1}{2}} \\
 &= 119,06
 \end{aligned}$$

Begitupun untuk selanjutnya sampai x_{340}

$$\begin{aligned}
\psi_1(x_{340}, c_1) &= ((x_{340} - c_1)^2 + \sigma^2)^{\frac{1}{2}} \\
&= ([(X_{t-1} - c_1)^2 + (X_{t-2} - c_1)^2 + \dots + (X_{t-19} - c_1)^2] + \sigma^2)^{\frac{1}{2}} \\
&=([(11,67 - 74,68)^2 + (22,28 - 73,89)^2 + \dots + (50,92 - 6,47)^2] + 35,07)^{\frac{1}{2}} \\
&= 119,09
\end{aligned}$$

⋮

$$\begin{aligned}
\psi_{10}(x_{340}, c_8) &= ((x_{340} - c_8)^2 + \sigma^2)^{\frac{1}{2}} \\
&= ([(X_{t-1} - c_8)^2 + (X_{t-2} - c_8)^2 + \dots + (X_{t-12} - c_8)^2] + \sigma^2)^{\frac{1}{2}} \\
&=([(11,67 - 11,67)^2 + (22,28 - 22,28)^2 + \dots + (50,92 - 50,92)^2] + 29,76)^{\frac{1}{2}} \\
&= 5,46
\end{aligned}$$

Sehingga diperoleh:

$$\begin{bmatrix} 1 & 5,91 & \cdots & 119,06 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 119,09 & \cdots & 5,46 \end{bmatrix} \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{10} \end{bmatrix} = \begin{bmatrix} 81,72 \\ 90,23 \\ \vdots \\ 9,38 \end{bmatrix}$$

Menggunakan metode *least square* diperoleh

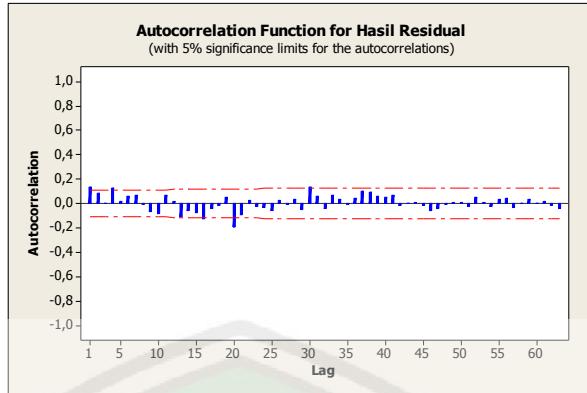
$$\begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{10} \end{bmatrix} = \left(\begin{bmatrix} 1 & 5,91 & \cdots & 119,06 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 119,09 & \cdots & 5,46 \end{bmatrix}^T \begin{bmatrix} 1 & 5,91 & \cdots & 119,06 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 119,09 & \cdots & 5,46 \end{bmatrix} \right)^{-1}$$

$$\begin{bmatrix} 1 & 5,91 & \cdots & 119,06 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 119,09 & \cdots & 5,46 \end{bmatrix}^T \begin{bmatrix} 81,72 \\ 90,23 \\ \vdots \\ 9,38 \end{bmatrix}$$

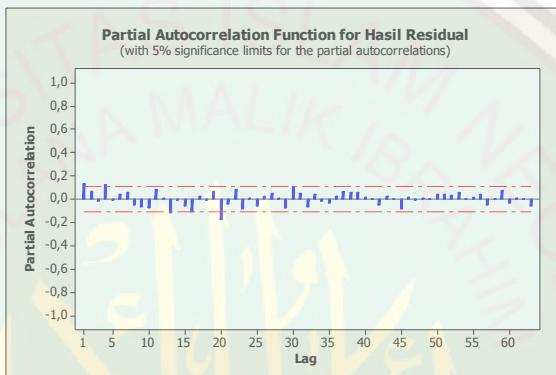
$$\begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{10} \end{bmatrix} = \begin{bmatrix} -0,1783 \times 10^3 \\ -2,7812 \times 10^3 \\ \vdots \\ 2,2680 \times 10^3 \end{bmatrix}$$

4.2.5 Uji Kesesuaian Model

Model yang diperoleh adalah 19 *input* dan 10 *neuron* pada lapisan *hidden*, kemudian dilakukan pengecekan *error* pada model tersebut. Gambar 4.9 dan 4.10 menunjukkan *plot ACF* dan *plot PACF* dari residual sebagai berikut:



Gambar 4.14 Plot ACF hasil residual



Gambar 4.15 Plot PACF hasil residual

Pada gambar 4.14 dan gambar 4.15 menunjukkan bahwa hanya *lag* 1 dan *lag* 18 yang melebihi garis kepercayaan tapi tidak signifikan. Hal ini menunjukkan tidak ada *lag* yang signifikan yang artinya *error* bersifat acak atau *white noise* terpenuhi. Oleh sebab itu, model RBFNN dapat digunakan.

4.2.6 Peramalan

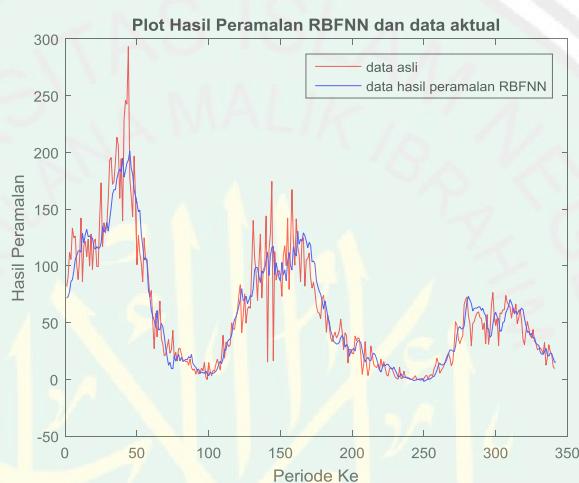
Jaringan arsitektur yang digunakan dalam peramalan jumlah bilangan *sunspot* adalah 19 *input*, 10 *neuron* tersembunyi dan 1 *output*. Diperoleh persamaan RBF untuk peramalan sebagai berikut:

$$f(x) = \sum_{j=1}^m w_j \psi_j(x, c_j)$$

$$\begin{aligned}
 f(x) = & w_0 + w_1\psi_1(x, c_1) + w_2\psi_2(x, c_2) + w_3\psi_3(x, c_3) + w_4\psi_4(x, c_4) \\
 & + w_5\psi_5(x, c_5) + w_6\psi_6(x, c_6) + w_7\psi_7(x, c_7) + w_8\psi_8(x, c_8) \\
 & + w_9\psi_9(x, c_9) + w_{10}\psi_{10}(x, c_{10})
 \end{aligned}$$

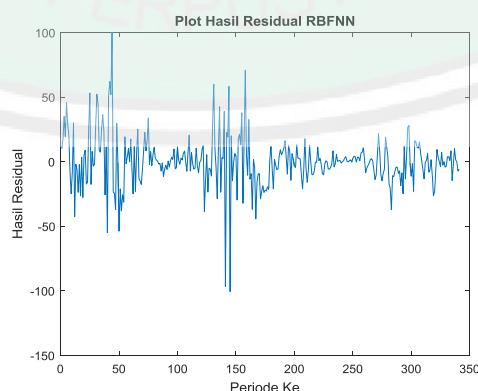
$$\begin{aligned}
 f(x) = & -178,3 - 2.781,2 \times 10^3\psi_1(x, c_1) - 131,5\psi_2(x, c_2) - 11,7\psi_3(x, c_3) \\
 & + 852\psi_4(x, c_4) + 9,3\psi_5(x, c_5) + 3,6(x, c_6) - 138,9\psi_7(x, c_7) \\
 & + 334,3\psi_8(x, c_8) + 36,9\psi_9(x, c_9) + 2.268\psi_{10}(x, c_{10})
 \end{aligned}$$

Berikut *plot* data aktual dan hasil peramalan menggunakan RBFNN untuk data *training* dan data *testing*.



Gambar 4.16 *Plot* data dan hasil peramalan

Dari gambar 4.16 terlihat pada periode tertentu hasil peramalan belum mendekati hasil sebenarnya. Adapun *plot* hasil residual dari data aktual dengan hasil peramalan, sebagai berikut:



Gambar 4.17 *Plot* Hasil Residual

Dari gambar 4.17 terlihat bahwa pada periode tertentu hasil peramalan dengan data aktual berbeda cukup jauh. Sedangkan hasil *error* yang diperoleh, seperti pada tabel 4.3:

Tabel 4.8 Hasil *error* RBFNN setiap siklus

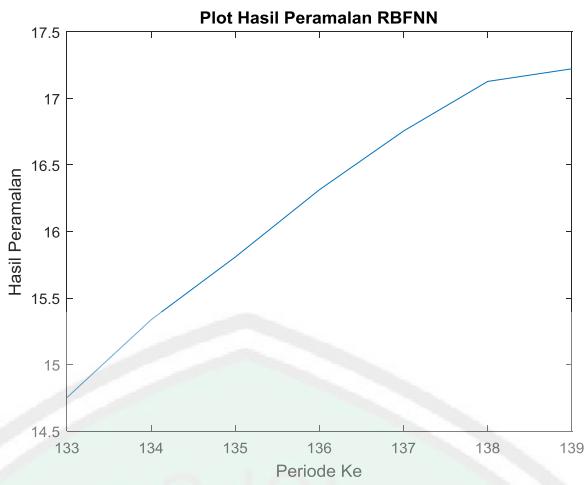
Periode	Siklus ke	Error (%)
Jan (1987) – Okt (1996)	22	32%
Nov (1997) – Ags (2008)	23	43%
Sep (2008) – Des (2016)	24	33%

Dari tabel di atas terlihat hasil *error* terbesar ada pada siklus ke 23, sebesar 43% sedangkan pada siklus 22 dan 24 mencapai 32 dan 33%. Adapun perhitungan peramalan untuk periode-periode berikutnya, sebagai berikut:

Tabel 4.9 Hasil peramalan RBFNN

Periode	Hasil Peramalan
133	14,75
134	15,37
135	15,81
136	16,31
137	16,76
138	17,13
139	17,22

Adapun *plot* dari hasil peramalan, sebagai berikut:



Gambar 4.18 Plot hasil peramalan RBFNN

Grafik di atas menjelaskan bahwa jumlah bilangan *sunspot* mengalami peningkatan. Pada periode 133 ke 139 terjadi peningkatan jumlah bilangan *sunspot*. Tetapi perubahan yang terjadi tidak signifikan hal ini terjadi karena kondisi matahari memasuki periode akhir dan masuk ke periode terbaru. Sedangkan, analisis kesalahan sebagai berikut:

$$SSE = \sum_{t=1}^n (X_t - F_t)^2$$

$$= 6,7974 \times 10^1$$

$$MSE = \frac{1}{n} \sum_{t=1}^n (X_t - F_t)^2$$

$$= 0,9711 \times 10^1$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|X_t - F_t|}{X_t} 100\%$$

$$= 18,2\%$$

Didapatkan nilai dari MSE adalah $0,9711 \times 10^1$ dan MAPE sebesar 18,2%.

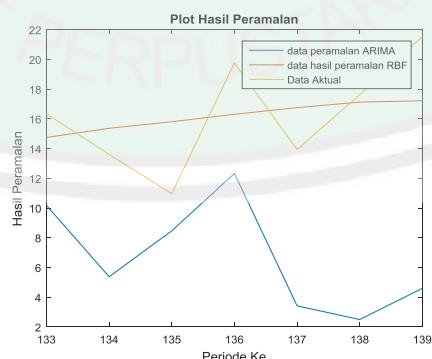
4.3 Perbandingan Hasil Ramalan dari ARIMA dengan RBFNN

Setelah dilakukan peramalan jumlah bilangan *sunspot* dengan metode ARIMA dan RBFNN, maka perbandingan hasil kedua metode ditunjukkan pada tabel dibawah ini:

Tabel 4.10 Hasil perbandingan data aktual, ARIMA dan RBFNN

Periode	Waktu	Data Aktual	Hasil ramalan		Hasil Error (%)	
			ARIMA	RBFNN	ARIMA	RBFNN
133	Januari 2017	16,34	10,18	14,75	37,8	9,7
134	Februari 2017	13,61	5,38	15,37	60,5	12,9
135	Maret 2017	10,97	8,47	15,81	22,8	44,1
136	April 2017	19,77	12,33	16,31	37,6	17,5
137	Mei 2017	13,94	3,42	16,76	75,5	20,2
138	Juni 2107	17,63	2,50	17,13	85,8	2,8
139	Juli 2017	21,55	4,60	17,22	78,7	20,1

Tabel di atas menunjukkan hasil peramalan menggunakan metode ARIMA dengan RBFNN untuk data bilangan *sunspot*. Adapun *plot* peramalan akan ditunjukkan sebagai berikut:



Gambar 4.19 *Plot* Data Aktual, ARIMA dan RBFNN

1. Peramalan dengan metode ARIMA

Peramalan menggunakan ARIMA menunjukkan bahwa pada periode 133 di angka 10,18 sedangkan untuk periode 134 di angka 5,38. Ini menunjukkan adanya penurunan tetapi pada periode 135 meningkat di angka 8,47 dan meningkat lagi pada periode 136 di angka 12,33. Pada periode 137 terjadi penurunan di angka 3,42 dan pada periode 138 juga menurun di angka 2,50 tetapi pada periode 139 meningkat di angka 4,60. Hal ini menunjukkan hasil peramalan tidak membentuk suatu pola linier. Pada data aktual dengan data peramalan ARIMA (gambar 4.10) memperlihatkan bahwa data aktual dengan peramalan cenderung menjauh tetapi pola fluktuasi peramalan hampir sama dengan data aktual, hal ini dikarenakan nilai $p-value$ pada lag 36 kurang dari α . Pada gambar 4.19 terlihat hasil peramalan ARIMA membentuk pola yang hampir sama dengan data aktual, tetapi hasil peramalan cenderung jauh dari data aktual. Hal ini menunjukkan ARIMA kurang baik digunakan untuk meramalkan data *sunspot*, sehingga perlu dikaji lagi data atau metode yang digunakan. Adapun hasil MSE untuk peramalan periode kedepan adalah:

$$MSE = 1,1345 \times 10^2$$

$$MAPE = 56,9\%$$

2. Peramalan dengan metode RBFNN

Peramalan menggunakan RBFNN menunjukkan bahwa pada periode 133 di angka 14,75 sedangkan untuk periode 134 di angka 15,37. Ini menunjukkan adanya peningkatan hal ini berlanjut pada periode 135 sampai 139 mulai di angka 15,81, 16,31, 16,76, 17,13 dan 17,22. Hal ini menunjukkan hasil RBFNN membentuk pola linier. Pada data aktual dengan data peramalan RBFNN (gambar 4.16) memperlihatkan bahwa data aktual dengan peramalan

cenderung mendekati tetapi pada periode tertentu agak berjauhan, sedangkan pola fluktuasi peramalan agak berjauhan dengan data aktual. Pada gambar 4.19 terlihat hasil peramalan RBFNN membentuk pola linier, dimana hasil peramalan cenderung jauh dari data aktual. Hal ini menunjukkan RBFNN kurang baik digunakan untuk meramalkan data *sunspot*, sehingga perlu dikaji lagi data atau metode yang digunakan. Adapun hasil MSE untuk peramalan periode kedepan adalah:

$$MSE = 0,9711 \times 10^1$$

$$MAPE = 18,2\%$$

Dari kedua metode yang digunakan ternyata hasil yang diperoleh kurang begitu baik, hal ini menunjukkan pola data yang tidak bisa diramalkan. Sehingga perlu dicari faktor lain yang mempengaruhi kondisi *sunspot* atau mengkaji metode yang digunakan.

4.4 Persepektif Islam

4.4.1 Perseptif Islam mengenai Matahari

Matahari merupakan salah satu bintang yang memproduksi panas serta cahaya, sebagaimana firman Allah dalam Surat an-Naba' ayat 12-13. Dalam ayat ini, matahari dinyatakan dengan kata "terbakar dan terang", karena cahaya dan terang merupakan sepasang karunia besar yang menjadi penampak seluruh materi di dunia ini.

Sedangkan menurut Bucaille, dalam ayat ini matahari dijelaskan sebagai suatu pelita yang sinarnya sangat kuat. Hal ini menunjukkan bahwa dalam al-Quran dengan apa yang kita ketahui sekarang yang telah diungkapkan oleh ilmu

pengetahuan tidaklah bertentangan. Sehingga benar bahwa matahari merupakan bola gas yang panas dan sangat besar.

Al-Quran juga menjelaskan tentang pengaturan samawi atau benda-benda langit seperti matahari. Hal yang dapat dipelajari terkait dengan sistem matahari. Selain itu terdapat fenomena-fenomena yang ada di luar sistem matahari yang sudah diteliti oleh para ilmuwan dengan berbagai ilmu pengetahuannya dan ada juga fenomena-fenomena dalam matahari.

Orbit matahari merupakan fenomena yang berhubungan dengan matahari, sebagaimana firman Allah dalam surat al-Anbiya' ayat 33 serta surat Yaasin ayat 40. Dalam ayat tersebut, telah disebutkan bahwa terdapat orbit matahari dan isyarat benda-benda langit yang berpindah dengan gerakan khusus. Dalam hal inilah ilmu pengetahuan sains sangatlah dibutuhkan dalam memahami ayat tersebut. Penelitian tentang matahari dan galaksi sangatlah dibutuhkan. Menurut satuan *disk* (bundaran) yang tengahnya lebih tebal dari pinggirnya, Galaksi kita memuat jumlah yang sangat besar dibandingkan bintang-bintang yang lain. Matahari menempati tempat yang jauh dari pusat *disk*. Hal inilah yang dijelaskan dan dibuktikan oleh para ilmuwan astronomi terkait orbit matahari serta bintang-bintang di dalamnya

4.4.2 Perseptif Islam Mengenai Ramalan

Peramalan merupakan cara dalam menilai sesuatu kejadian sebelumnya, sebagaimana firman Allah dalam surat Yusuf ayat 47-48. Dalam ayat ini tersirat makna bahwa nabi Yusuf mendapat perintah dari Allah untuk merencanakan tentang ekonomi pertanian dalam 7 tahun mendatang. Hal ini dilakukan untuk menghadapi krisis pangan (musim paceklik) yang terjadi.

Dalam agama Islam telah diatur mengenai ramalan atau prediksi, dimana ada yang boleh dan ada yang tidak. Salah satu contoh ramalan yang diperbolehkan terdapat dalam surat Yusuf mengenai masalah perekonomian.

Al-Quran merupakan sumber dari segala macam ilmu, salah satunya peramalan. Sebagaimana yang tercantum dalam surat Yusuf ayat 47-48 mengenai masalah perekonomian. Dalam masalah ini nabi Yusuf memberikan saran untuk diadakanya perencanaan pertanian yang dalam praktiknya diserahkan kepada nabi Yusuf, berkat perencanaan ini, Mesir dan daerah sekelilingnya turut mendapat berkahnya.

Di dalam ilmu Matematika terdapat cabang ilmu Statistik yang di dalamnya terdapat beberapa metode peramalan, peramalan dalam metode ini diperbolehkan, karena peramalan yang dimaksud peramalan secara Ilmiah. Dimana yang diterapkan terdiri dari penelitian-penelitian ilmiah yang disiplin ilmu dan sudah teruji semua kebenarannya, ini terlepas dari peramalan yang berhubungan nasib manusia. Pada penelitian yang dilakukan peneliti ini berupa meramalkan jumlah bilangan *sunspot*, bertujuan agar manusia bisa mempersiapkan lebih dini akan dampak dari *sunspot*, karena jumlah bilangan *sunspot* mempengaruhi aktifitas yang ada di matahari.

Manusia melakukan peramalan dalam upaya mencari pegangan dalam pengambilan suatu keputusan, meskipun hasil dari perencanaan manusia bisa berubah sesuai dengan upaya yang dilakukan untuk menjadi lebih baik, sebagaimana firman Allah dalam surat ar-Ra'ad ayat 11. Dalam ayat ini, Allah memiliki malaikat yang memantau manusia secara bergiliran dari depan maupun belakang. Malaikat ini menjaga berdasarkan perintah dari Allah Swt, untuk

menghitung amal perbuatan baik maupun buruk. Sesungguhnya Allah Swt tidak akan megubah nikmat suatu kaum sampai mereka mengubah ketaatan menjadi kemaksiatan. Hanya Allah yang dapat mengubah kesenangan menjadi kesengsaraan, nikmat menjadi cobaan.

Jika Allah Swt telah menghendaki bencana atau bala' pada suatu kaum maka tiada satupun yang bisa mencegahnya. Tiada tempat untuk menghindari ketetapan-Nya. Tidak akan ada penolong yang dapat membantu mereka dalam mendapatkan apa yang mereka suka dan menghalangi apa yang mereka benci. Hanya Allah Swt yang menentukan segala urusan hamba-hamba-Nya.



BAB V

PENUTUP

5.1 Kesimpulan

Dari hasil pembahasan, didapatkan hasil ARIMA dan RBFNN sebagai berikut:

1. Model ARIMA

Dalam ARIMA hal yang perlu dilakukan dalam peramalan adalah: 1) membuat *plot*, 2) Stasioneritas (jika belum stasioner dilakukan trasformasi *differencing*), 3) identifikasi, 4) panaksiran parameter, 5) menguji validasi model. Berdasarkan hal ini diperoleh model ARIMA musiman yaitu ARIMA $(0,1,1)(1,1,1)^{11}$, adapun persamaan umumnya:

$$X_t = X_{t-1} - 0,0497 + 0,1541X_{t-11} - 0,1541X_{t-12} - 0,5344\alpha_{t-1} - 0,9585\alpha_{t-11}$$

Dengan $MSE = 1,1345 \times 10^2$ dan $MAPE = 56,9\%$.

2. Jaringan RBFNN

Dalam RBFNN hal yang perlu dilakukan dalam peramalan adalah: 1) identifikasi model, 2) pembagian data, 3) menentukan jaringan optimum, 4) penaksiran parameter, 5) uji kesesuaian model. Diperoleh 19 *input*, 10 *neuron*, dan 1 *output* sebagai arsitektur jaringan yang terbaik. Diperoleh persamaan umumnya:

$$\begin{aligned} f(x) = & -178,3 - 2.781,2 \times 10^3 \psi_1(x, c_1) - 131,5 \psi_2(x, c_2) - 11,7 \psi_3(x, c_3) \\ & + 852 \psi_4(x, c_4) + 9,3 \psi_5(x, c_5) + 3,6(x, c_6) - 138,9 \psi_7(x, c_7) \\ & + 334,3 \psi_8(x, c_8) + 36,9 \psi_9(x, c_9) + 2.268 \psi_{10}(x, c_{10}) \end{aligned}$$

Dengan $MSE = 0,9711 \times 10^1$ dan $MAPE = 18,2\%$.

Dari hasil kedua metode tersebut ternyata kedua metode mempunyai pola yang hampir sama dengan data aktual, tetapi hasil ARIMA cenderung menjauh sementara hasil RBFNN cenderung menjauh pada periode tertentu. Hal ini dapat dilihat dari *error* yang didapatkan dimana *error* arima mencapai 56% sedangkan RBFNN mencapai 18,2%. Sedangkan hasil MSE yang diperoleh secara angka metode RBFNN mempunyai MSE yang lebih kecil tetapi pola yang dibentuk cenderung linier berbeda dengan ARIMA yang polanya hampir sesuai dengan data aktualnya tetapi hasilnya cenderung jauh,.hasil ini dikarenakan dalam metode ARIMA pada *lag*-36 (tabel 4.2) nilai *p – value* kurang dari $\alpha(5\%)$. Sehingga untuk penelitian selanjutnya bisa menggunakan metode lain atau melakukan analisis model ARIMA yang terbaik.

5.2 Saran

Berdasarkan hasil dari pembahasan serta penelitian di atas, metode ARIMA hasilnya kurang bagus cenderung menjauh berbeda dengan RBFNN, sehingga peneliti menyarankan untuk menggunakan metode lain atau mencari alternatif model terbaik atau menggunakan kedua metode untuk data yang lain. Selain itu pengambilan vektor pusat sangat mempengaruhi hasil RBFNN.

DAFTAR PUSTAKA

- Artaber, A. 2016. *Penyelesaian Numerik Persamaan Diferensial Biasa Linier Orde-4 Menggunakan Jaringan Radial Basis Function*. Universitas Islam Negeri Maulana Malik Ibrahim Malang.
- Aswi, and Sukarna. 2006. *Analisis Deret Waktu dan Aplikasi*. Makassar: Andira Publisher.
- Boediono and Wayan, K. 2004. *Teori dan Aplikasi Statistika dan Probabilitas*. Bandung: P.T Remaja Rosdakarya Offset.
- Brockwell, P. . and Davis, R. 2002. ‘Introduction to Time Series and Forecasting 2’, *Springer Science and Business*.
- Bucaille, M. 1976. *Bibel Qur'an dan Sains Modern*. Jakarta: Bulan Bintang
- Fausett, L. 1994. *Fundamentals of Neural Networks (Architectures, Algorithms, and Application)*. New Jersey: Prentice
- Hanke, J. E. & Wichern, D. W. 2005. *Business Forecasting Eight Edition*. New Jersey: Pearson Prenticehall.
- Hathaway, D. H., Wilson, R. M. and Reichmann, E. 2002. ‘Group Sunspot Numbers: Sunspot Cycle Characteristic’, *Solar Phys*, 211, p. 357.
- Kuontur, R. 2004.. *Metode Penelitian*. Jakarta: PPM
- Maspupu, J. 2011. ‘Prediksi Bintik Matahari untuk Siklus 24 Secara Numerik’, (133).
- Mulyono, S. 2000. *Peramalan Bisnis dan Ekonometri*. Pertama. Yogyakarta: BPFE.
- Munawaroh, A. N. 2010. Peramalan Jumlah Penumpang pada PT. Angkasa Pura I (PERSERO) Kantor Cabang Bandar Udara Internasional Adisutjipto Yogyakarta dengan Metode *Winter's Exponential Smoothing* dan *Seasonal ARIMA*. Skripsi. Yogyakarta: Fakultas Matematika dan Ilmu Pengetahuan Alam Universita Negeri Yogyakarta.
- Setiahadi, B. 2001. ‘Hasil Uji Simulasi MHD Matahari-Bumi’, *Observatorium*

Matahari Watukosek, LAPAN.

- Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods Second Edition*. New Jersey: Pearson Prentice Hall
- Wei, S. et al. 2011. ‘Forecasting Stock Indices Using Radial Basis Function Neural Networks Optimized by Artificial Fish Swarm Algorithm’, *Knowledge Based System*, 24, pp. 378–385.
- Wiyanti, D. and Pulungan, R. 2012. ‘Peramalan Deret Waktu Menggunakan Model Fungsi Basis Radial (RBF) dan Auto Regressive Integrated Moving Average (ARIMA)’, *Jurnal MIPA*, 35(2), pp. 175–182.
- Yeung, D. S. et al. 1998. *Sensitivity Analysis for Neural Network*. London: Springer.

LAMPIRAN-LAMPIRAN

Lampiran 1 Data Bulanan *Sunspot*

Periode	Rata-rata Bilangan <i>Sunspot</i> (bintik)
Jan-87	6,47
Feb-87	2,36
Mar-87	11,4
Apr-87	33,12
Mei-87	28,42
Jun-87	28,42
Jul-87	36,76
Agu-87	34,97
Sep-87	31,73
Okt-87	52,71
Nov-87	31,74
Des-87	18,33
Jan-88	38,34
Feb-88	21,29
Mar-88	44,34
Apr-88	61,45
Mei-88	35,64
Jun-88	73,89
Jul-88	74,86
Agu-88	81,72
Sep-88	90,23
Okt-88	111,93
Nov-88	105,76
Des-88	133,34
Jan-89	124,96
Feb-89	126,26
Mar-89	101,09
Apr-89	88,08
Mei-89	105,54
Jun-89	142,12
Jul-89	86,25
Agu-89	118,37
Sep-89	121,39
Okt-89	108,3
Nov-89	123,44
Des-89	99,89
Jan-90	127,92
Feb-90	96,84
Mar-90	121,13
Apr-90	123,67
Mei-90	99,57
Jun-90	99,41
Jul-90	141,57

Agu-90	173,17
Sep-90	116,98
Okt-90	137,84
Nov-90	129,02
Des-90	136,01
Jan-91	159,29
Feb-91	193,2
Mar-91	195,42
Apr-91	171,98
Mei-91	174,57
Jun-91	192
Jul-91	213,35
Agu-91	206,22
Sep-91	159,58
Okt-91	194,47
Nov-91	139,78
Des-91	228,59
Jan-92	245,84
Feb-92	242,54
Mar-92	293,16
Apr-92	177,48
Mei-92	161,56
Jun-92	143,42
Jul-92	196,72
Agu-92	160,7
Sep-92	101,17
Okt-92	126,77
Nov-92	110,88
Des-92	102,85
Jan-93	86,14
Feb-93	124,69
Mar-93	105,73
Apr-93	106,08
Mei-93	88,75
Jun-93	72,77
Jul-93	78,22
Agu-93	50,54
Sep-93	27,19
Okt-93	57,99
Nov-93	37,56
Des-93	51,1
Jan-94	68,82
Feb-94	36,06
Mar-94	31,28
Apr-94	20,92
Mei-94	21,86
Jun-94	28,41

Jul-94	35,15
Agu-94	23,23
Sep-94	26,1
Okt-94	43,1
Nov-94	18,33
Des-94	23,88
Jan-95	16,16
Feb-95	26,88
Mar-95	27,4
Apr-95	22,06
Mei-95	16,89
Jun-95	16,87
Jul-95	15,72
Agu-95	15,78
Sep-95	12,6
Okt-95	17,88
Nov-95	10,25
Des-95	8,07
Jan-96	9,18
Feb-96	4,6
Mar-96	8,69
Apr-96	4,68
Mei-96	6,1
Jun-96	9,81
Jul-96	7,68
Agu-96	14,96
Sep-96	1,93
Okt-96	00,00
Nov-96	14,63
Des-96	7,44
Jan-97	3,23
Feb-97	7,97
Mar-97	7,22
Apr-97	13,36
Mei-97	17,57
Jun-97	13,12
Jul-97	8,39
Agu-97	21,05
Sep-97	38,8
Okt-97	18,82
Nov-97	32,78
Des-97	31,31
Jan-98	28,92
Feb-98	30,86
Mar-98	49,76
Apr-98	44,26
Mei-98	44,21

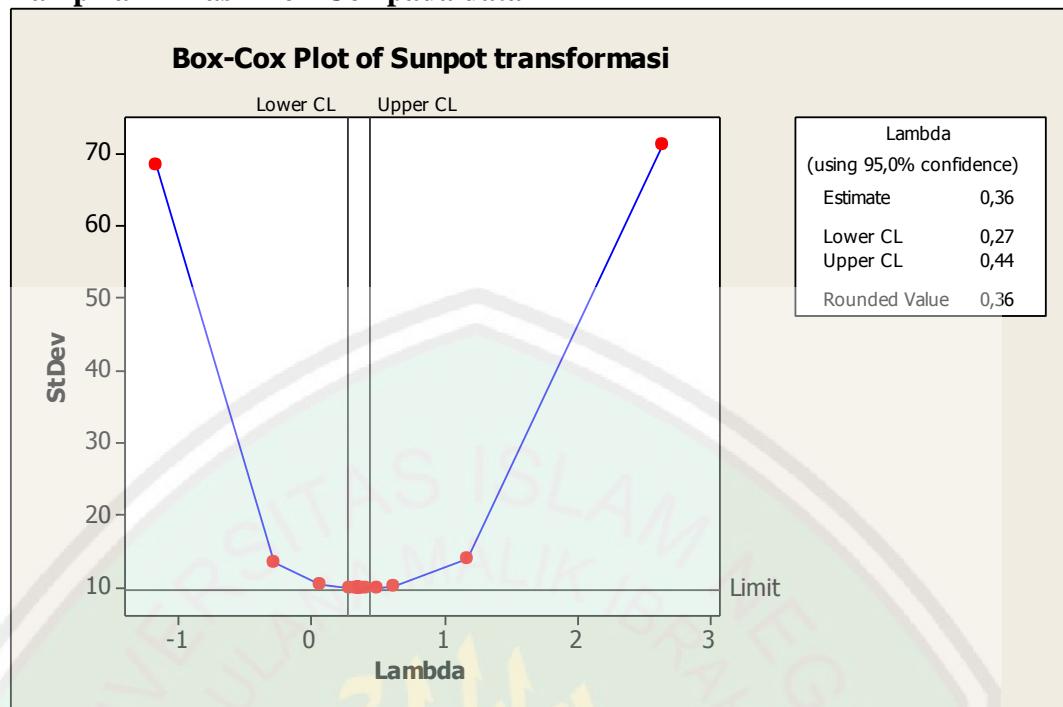
Jun-98	54,36
Jul-98	60,3
Agu-98	73,93
Sep-98	83,35
Okt-98	41,19
Nov-98	55,79
Des-98	75,29
Jan-99	49,65
Feb-99	61,8
Mar-99	64,15
Apr-99	62,75
Mei-99	100,66
Jun-99	139,98
Jul-99	107,25
Agu-99	93,7
Sep-99	69,6
Okt-99	102,34
Nov-99	127,94
Des-99	71,88
Jan-00	96,58
Feb-00	99,43
Mar-00	143,97
Apr-00	125,47
Mei-00	114,36
Jun-00	128,29
Jul-00	174,38
Agu-00	16,44
Sep-00	112,51
Okt-00	87,74
Nov-00	94,93
Des-00	95,82
Jan-01	91,18
Feb-01	73,25
Mar-01	109,4
Apr-01	117,62
Mei-01	100,26
Jun-01	142,06
Jul-01	79,4
Agu-01	117,71
Sep-01	167,23
Okt-01	121,75
Nov-01	100,73
Des-01	141,38
Jan-02	116,96
Feb-02	109,85
Mar-02	86,4
Apr-02	123,49
Mei-02	124,63
Jun-02	82,28
Jul-02	105,46

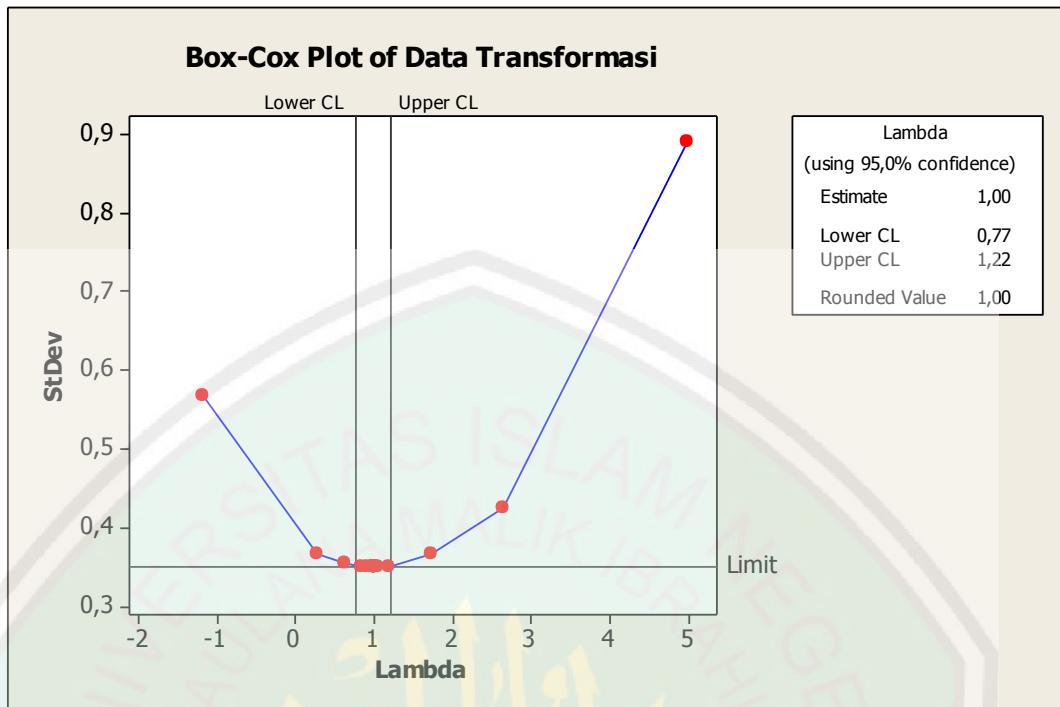
Agu-02	106,44
Sep-02	111,32
Okt-02	89,41
Nov-02	80,5
Des-02	85,49
Jan-03	78,05
Feb-03	65,27
Mar-03	59,22
Apr-03	58,36
Mei-03	53,66
Jun-03	71,2
Jul-03	73,99
Agu-03	63,63
Sep-03	41,68
Okt-03	56,45
Nov-03	47,8
Des-03	36,64
Jan-04	33,4
Feb-04	37,81
Mar-04	41,52
Apr-04	36,48
Mei-04	38,81
Jun-04	42,89
Jul-04	53,04
Agu-04	42,07
Sep-04	26,35
Okt-04	41,00
Nov-04	38,73
Des-04	14,57
Jan-05	26,61
Feb-05	26,28
Mar-05	22,87
Apr-05	22,72
Mei-05	38,16
Jun-05	34,32
Jul-05	36,61
Agu-05	35,77
Sep-05	21,47
Okt-05	4,56
Nov-05	12,93
Des-05	33,2
Jan-06	12,22
Feb-06	3,47
Mar-06	10,47
Apr-06	29,33
Mei-06	21,22
Jun-06	13,06
Jul-06	11,46
Agu-06	10,4
Sep-06	13,23

Okt-06	8,11
Nov-06	17,72
Des-06	11,12
Jan-07	15,5
Feb-07	9,63
Mar-07	3,98
Apr-07	2,97
Mei-07	9,38
Jun-07	10,34
Jul-07	8,59
Agu-07	5,01
Sep-07	2,04
Okt-07	0,83
Nov-07	0,28
Des-07	10,72
Jan-08	0,8
Feb-08	1,02
Mar-08	7,4
Apr-08	1,92
Mei-08	1,77
Jun-08	1,66
Jul-08	0
Agu-08	0
Sep-08	0,29
Okt-08	1,66
Nov-08	3,14
Des-08	0
Jan-09	0,46
Feb-09	0,27
Mar-09	0,8
Apr-09	0
Mei-09	0,71
Jun-09	3,08
Jul-09	3,42
Agu-09	0
Sep-09	3,31
Okt-09	4,23
Nov-09	2,88
Des-09	9,15
Jan-10	12,06
Feb-10	18,57
Mar-10	14,44
Apr-10	5,59
Mei-10	7,77
Jun-10	9,78
Jul-10	12,5
Agu-10	16,95
Sep-10	21,17
Okt-10	22,86
Nov-10	19,23

Des-10	12,14
Jan-11	15,36
Feb-11	30,55
Mar-11	51
Apr-11	47,65
Mei-11	35,27
Jun-11	31,66
Jul-11	35,39
Agu-11	38,37
Sep-11	65,62
Okt-11	70,35
Nov-11	72,99
Des-11	55,68
Jan-12	49,54
Feb-12	29,54
Mar-12	49,41
Apr-12	54,6
Mei-12	55,34
Jun-12	58,59
Jul-12	59,53
Agu-12	54,71
Sep-12	53,64
Okt-12	43,98
Nov-12	49,67
Des-12	31,27
Jan-13	56,41
Feb-13	30,98
Mar-13	41,5
Apr-13	65,36
Mei-13	79,15
Jun-13	55,25
Jul-13	7,71
Agu-13	53,6
Sep-13	29,95
Okt-13	58,47
Nov-13	57,79
Des-13	61,12
Jan-14	61,45
Feb-14	73,86
Mar-14	67,95
Apr-14	64,81
Mei-14	63,67
Jun-14	54,02
Jul-14	62,61
Agu-14	58,78
Sep-14	66,35
Okt-14	49,18
Nov-14	54,14
Des-14	61,82
Jan-15	52,66

Feb-15	35,9
Mar-15	30,44
Apr-15	41,16
Mei-15	50,92
Jun-15	45,78
Jul-15	39,15
Agu-15	36,19
Sep-15	43,87
Okt-15	33,86
Nov-15	31,91
Des-15	26,36
Jan-16	26,75
Feb-16	27,86
Mar-16	26,05
Apr-16	23
Mei-16	32,57
Jun-16	12,79
Jul-16	18,94
Agu-16	30,52
Sep-16	24,63
Okt-16	22,69
Nov-16	11,67
Des-16	9,38

Lampiran 2 Hasil Box-Cox pada data

Lampiran 3 Hasil Box-Cox pada data transformasi

Lampiran 4 Nilai c_j

	c_1	c_2	c_3	c_4	c_5	c_6	c_7	c_8	c_9	c_{10}
x_{19}	6,47	123,67	78,22	0	96,58	58,36	11,46	4,23	56,41	50,92
x_{18}	2,36	99,57	50,54	14,63	99,43	53,66	10,4	2,88	30,98	45,78
x_{17}	11,4	99,41	27,19	7,44	143,97	71,2	13,23	9,15	41,5	39,15
x_{16}	33,12	141,57	57,99	3,23	125,47	73,99	8,11	12,06	65,36	36,19
x_{15}	28,42	173,17	37,56	7,97	114,36	63,63	17,72	18,57	79,15	43,87
x_{14}	28,42	116,98	51,1	7,22	128,29	41,68	11,12	14,44	55,25	33,86
x_{13}	36,76	137,84	68,82	13,36	174,38	56,45	15,5	5,59	7,71	31,91
x_{12}	34,97	129,02	36,06	17,57	16,44	47,8	9,63	7,77	53,6	26,36
x_{11}	31,73	136,01	31,28	13,12	112,51	36,64	3,98	9,78	29,95	26,75
x_{10}	52,71	159,29	20,92	8,39	87,74	33,4	2,97	12,5	58,47	27,86
x_9	31,74	193,2	21,86	21,05	94,93	37,81	9,38	16,95	57,79	26,05
x_8	18,33	195,42	28,41	38,8	95,82	41,52	10,34	21,17	61,12	23
x_7	38,34	171,98	35,15	18,82	91,18	36,48	8,59	22,86	61,45	32,57
x_6	21,29	174,57	23,23	32,78	73,25	38,81	5,01	19,23	73,86	12,79
x_5	44,34	192	26,1	31,31	109,4	42,89	2,04	12,14	67,95	18,94
x_4	61,45	213,35	43,1	28,92	117,62	53,04	0,83	15,36	64,81	30,52
x_3	35,64	206,22	18,33	30,86	100,26	42,07	0,28	30,55	63,67	24,63
x_2	73,89	159,58	23,88	49,76	142,06	26,35	10,72	51	54,02	22,69
x_1	74,86	194,47	16,16	44,26	79,4	41	0,8	47,65	62,61	11,67
var	35,07	158,81	36,63	20,5	105,43	47,2	8,01	17,57	55,03	29,76

Lampiran 5 Program ARIMA

```
clc,clear
```

```
A=linspace(1,1,348);
load E:\program\data_arima.txt;
B=data_arima(:,1); C=data_arima(:,2); D=data_arima(:,3);
E=data_arima(:,1:348); ff=data_arima(:,1:348);
F=data_arima(:,1:348);

a=A';
b=(C-B)';
c=(D-C)';
Y=(E-D)';
X=[a c b];
x=X';
G=x*X;
g=inv(G);
PHI=g*x*Y

err=Y-X*PHI
n=348;
error_SSE = sum(err.^2);
tes= 75.0109*347;

YY=Y(3:348,:);
err1=err(1:346,:);
err2=err(2:347,:);
err3=err(3:348,:);
yy=YY-err3
TT=[err2 err1];
tt=TT';
GG=tt*TT;
gg=inv(GG);
thte=gg*tt*yy

uu=ff'+(X(3:348,:)*PHI+TT*thte);
yui=F';
errr=sqrt((yui(8:346,1)-uu(8:346,1)).^2);
tuo=errr.^2;
error_SSE1 = sum(tuo)
mpe=mean(abs(errr./yui(8:346,1)))

plot(F', 'r');
hold on
plot(uu, 'b');
legend('data asli','data hasil peramalan')
```

Lampiran 6 Program RBFNN

➤ Program *globalridge*

```

function [l, e, L]=globalRidge(H,Y,l)

Verbose=0;
Flops=0;
Model='g';
Threshold=1000;
Hard=100;
Standard=1;

if nargin > 3
    i=1;
    [arg, i]=getNextArg(options,i);

    while ~isempty(arg)
        if strcmp(arg, '-v')
            Verbose=1;
        elseif strcmp(arg, '-V')
            Verbose=1;
            Flops=1;
        elseif strcmp(arg, '-U')
            Standard=0;
        elseif strcmp(arg, '-h')
            [arg,i]=getNextArg(options,i);
            h1=str2double(arg);
            if ~isempty(H1)
                if h1>1
                    Hard=round(h1);
                else
                    fprintf('globalRidge: hard Limit should be
positive\n');
                    error('globalRidge: bad value in -h option');
                end
            else
                fprintf('globalRidge: value needed for hard
limit\n');
                error('globalRidge: misssing value in -h option');
            end
        elseif strcmp(arg, '-t')
            [arg,i]=getNextArg(options,i);
            te=str2double(arg);
            if ~isempty(te)
                if te >= 1
                    Threshold=round(te);
                elseif te > 0
                    Threshold=te;
                else
                    fprintf('globalRidge: threshold should be
positive\n');
                    error('globalRidge: bad value in -t option');
                end
            else
                fprintf('globalRidge: value needed for
threshold\n');
                error('globalRidge: missing value in -t option');
            end
        elseif strcmp(arg, 'uev')

```

```

        Model='u';
    elseif strcmpi(arg, 'fpe')
        Model='f';
    elseif strcmpi(arg, 'gcv')
        Model='g';
    elseif strcmpi(arg, 'bic')
        Model='b';
    else
        fprintf('%s\n',options)
        for k=1:i-length(arg)-1
            fprintf(' ');
        for k=1:length(arg)
            fprintf('^');
        fprintf('\n')
        error('globalRidge: unrecognised option')
    end
    [arg, i]=getNextArg(options, i);
end
if nargin < 3
    l=0.01;
end
if ~Standard
    if nargin < 5
        fprintf('globalRidge: specify non-standard penalty
matrix\n')
        error('globalRidge: -U option implies fifth argument')
    end
else
    U=1;
end

[~,m]=size(H);
[p,~]=size(Y);
[q1,q2]=size(l);
if q1==1
    q=q2;
elseif q2==1
    q=q1;
else
    error('globalRidge:list of quesses should be vector, not
matrix')
end
[u1,u2]=size(U);
if u1==m && u2==m
    H=H/U;
elseif u1 ~= 1 || u2 ~= 1
    estr=sprintf('%d-by%d', m,m);
    error(['globalRidge: U should be 1-by1 or' estr])
end
HH=H'*H;
HY=H'*Y;
e=zeros(1,q);
if nargout>2
    L=zeros(Hard+1,q);end
if nargout>3
    E=zeros(Hard+1,q);end
maxcount=1;
if Verbose

```

```

        fprintf('\n globalRidge\n')
    end
    if Flops
        flops(0)
    end

    for i=1:q
        if Verbose
            fprintf('pass')
            fprintf(' lambda ')
            if Model == 'u'
                fprintf(' UEV ')
            elseif Model == 'f'
                fprintf(' FPE ')
            elseif Model == 'g'
                fprintf(' GCV ')
            else
                fprintf(' VIC ')
            end
            fprintf(' change ')
            if Flops
                fprintf(' flops\n')
            else
                fprintf('\n')
            end
        end
        notTooMany=1;
        notDone=1;
        count=0;
        A=inv(HH+l(i)*eye(m));
        g=m-l(i)*trace(A);
        PY=Y-H*((HH+l(i)*eye(m))\HY);
        YPY=trace(PY'*PY);
        if Model == 'u'
            psi=p/(p-g);
        elseif Model == 'f'
            psi=(p+g)/(p-g);
        elseif Model == 'g'
            psi=p^2/(p-g)^2;
        else
            psi=(p+(log(p)-1)*g)/(p-g);
        end
        e(i)=psi*YPY/p;
        if Verbose
            fprintf('%4d %9.3e %9.3e -', count, l(i), e(i))
            uf Flops
            fprintf('%9d\n', flops)
        else
            fprintf('\n')
        end
    end
    if nargout>2
        L(l,i)=l(i);end
    if nargout>3
        E(l,i)=e(i);end
    while notDone && notTooMany
        count=count+1;
        A2=A^2;
        A3=A*A2;

```

```

if Model =='u'
    eta = 1/(2*(p-g));
elseif Model == 'f'
    eta = p/((p-g)*(p+g));
elseif Model == 'g'
    eta = 1/(p-g);
else
    eta = p*log(p)/(2*(p-g)*(p+(log(p)-1)*g));
end
n1=eta*YPY*trace(A-l(i)*A2)/trace(HY'*A3*HY);

if nargout>2
    L(count+1, i)=n1; end

A=inv(HH+n1*eye(m));
g=m-n1*trace(A);
PY=Y-H*((HH+n1*eye(m))\HY);
YPY=trace(PY'*PY);
if Model == 'u'
    psi=p/(p-g);
elseif Model == 'f'
    psi=(p+g)/(p-g);
elseif Model == 'g'
    psi=p^2/(p-g)^2;
else
    psi=(p+(log(p)-1)*g)/(p-g);
end
ns=psi*YPY/p;
if nargout>3
    E(count+1,i)=ns; end

if Threshold >= 1
    change=round(abs(e(i)/(e(i)-ns)));
else
    change=abs(e(i)-ns);
end

if count >= Hard
    notTooMany=0;
elseif Threshold >=1
    if change >Threshold
        notDone=0;
    end
else
    if change < Threshold
        notDone=0;
    end
end

l(i)=n1;
e(i)=ns;

if Verbose
    fprintf('%4d %9.3e %9.3e', count,l(i), e(i))
    if Threshold >=1
        fprintf('%7d', change)

```

```

        else
            fprintf('%7.1e',change)
        end
        if Flops
            fprintf('%9d\n',flops)
        else
            fprintf('\n')
        end
    end
end
if Verbose
    if ~notTooMany
        fprintf('hard limit reached\n')
    else
        if Threshold >=1
            fprintf('relative')
        else
            fprintf('absolute')
        end
        fprintf('ythreshold in')
    end
end
end

```

➤ Program *rbfDesign*

```

function H = rbfDesign(X, C, R, options)
type=2;
bias=0;
if nargin > 3
    for option = options;
        if option =='g'
            type = 0;
        elseif option =='c'
            type = 1;
        elseif option =='m'
            type = 2;
        elseif option =='i'
            type = 3;
        elseif option =='b'
            bias = 1;
        else
            error('rbfDesign: illegal option')
        end
    end
end
[n,p]=size(X);
[n1,m]=size(C);
if n~=n1
    error('rbfDesign: mismatched X, C')
end
[rr,rc]=size(R);
if rr == 1 && rc == 1;
    SCALING_TYPE = 1;
elseif rr == 1
    if rc == n
        SCALING_TYPE = 2;
        R = R';
    elseif rc == m

```

```

        SCALING_TYPE =4;
        R =R';
    else
        error('rbfDesign: mismatched C and row vector R')
    end
elseif rc == 1
    if rr == n
        SCALING_TYPE = 2;
elseif rr == m
        SCALING_TYPE = 4;
else
    error('rbfDesign: mismatched C and row vector R')
end
elseif rr == n
    if rc == n
        SCALING_TYPE = 3;
elseif rc == m
        SCALING_TYPE = 5;
else
    error('rbfDesign: mismatched C and matrix R')
end
elseif rc == n
    if rr == m
        SCALING_TYPE = 5;
        R = R';
else
    error('rbfDesign: mismatched C and matrix R')
end
else
    error('rbfDesign: wrong size R')
end
H = zeros(p,m);
for j = 1:m
    D = X-dupCol(C(:,j),p);
    if SCALING_TYPE == 1
        s = diagProduct(D',D)/R^2;
    elseif SCALING_TYPE == 2
        DR =D./dupCol(R,p);
        s = diagProduct(DR',DR);
    elseif SCALING_TYPE == 3
        DR = R\D;
        s = diagProduct(DR',DR);
    elseif SCALING_TYPE == 4
        s = diagProduct(D',D)/R(j)^2;
    else
        DR = D./dupCol(R(:,j),p);
        s = diagProduct(DR',DR);
    end
    if type == 0
        h = exp(-s);
    elseif type == 1
        h = 1./(s+1);
    elseif type == 2
        h = sqrt(s+1);
    elseif type == 3
        h = 1./sqrt(s+1);
    end
    H(:,j) = h;
end

```

```

if bias
    H = [H ones(p,1)];
end

function M = dupCol(v,n)
[~,c] = size(v);
if c~=1
    error('dupCol: input vector must be column')
end
M = v(:, ones(1,n));

function d = diagProduct(X,Y)
[m,n]=size(X);
[p,q]=size(Y);
if m~=q||n~=p
    error('diagProduct: bad dimensions')
end
P=X';
P=P(:);
Q=Y(:);
Z=zeros(n,m);
Z(:)=P.*Q;
d = colSum(Z)';

function s =colSum(X)
[m,~] = size(X);
if m > 1
    s = sum(X);
else
    s = X;
end

```

➤ Program peramalan

```

load E:\program\data_asli.txt;
X0=data_asli;
load E:\program\kluster_8.txt;
M=kluster_8(1:12,:); SD=kluster_8(13,:);

Y=X0(13:132,:);X1=X0(12:131,:);X2=X0(11:130,:);X3=X0(10:129,:);X4=
X0(9:128,:);X5=X0(8:127,:);X6=X0(7:126,:);X7=X0(6:125,:);X8=X0(5:1
24,:);X9=X0(4:123,:);X10=X0(3:122,:);X11=X0(2:121,:);X12=X0(1:120,
:);
X=[X1 X2 X3 X4 X5 X6 X7 X8 X9 X10 X11 X12];

[a,b]=size(X0); Yt=X0(132:a,:);
X1t=X0(131:a-1,:);X2t=X0(130:a-2,:);X3t=X0(129:a-
3,:);X4t=X0(128:a-4,:);X5t=X0(127:a-5,:);X6t=X0(126:a-
6,:);X7t=X0(125:a-7,:);X8t=X0(124:a-8,:);X9t=X0(123:a-
9,:);X10t=X0(122:a-10,:);X11t=X0(121:a-11,:);X12t=X0(120:a-12,:);
Xt=[X1t X2t X3t X4t X5t X6t X7t X8t X9t X10t X11t X12t];

Yu=X0(13:a,:);X1u=X0(12:a-1,:);X2u=X0(11:a-2,:);X3u=X0(10:a-
3,:);X4u=X0(9:a-4,:);X5u=X0(8:a-5,:);X6u=X0(7:a-6,:);X7u=X0(6:a-
7,:);X8u=X0(5:a-8,:);X9u=X0(4:a-9,:);X10u=X0(3:a-
10,:);X11u=X0(2:a-11,:);X12u=X0(1:a-12,:);
Xu=[X1u X2u X3u X4u X5u X6u X7u X8u X9u X10u X11u X12u];

```

```
H=rbfDesign(X',M,SD,'b');
lamb=globalRidge(H, Y, 0.05);
W=inv(H'*H+lamb*eye(9))*H'*Y;
%W=inv(H'*H*eye(9))*H'*Y;
ft=H*W;e=Y-ft; Jkt=(Y-mean(Y))'* (Y-mean(Y));
mpe=mean(abs(e./Y));
sse=e'*e;
MS=sse/120;
R2t=1-(sse/Jkt);

Hv=rbfDesign(Xt',M,SD,'b');
ftv=Hv*W;
ev=Yt-ftv;
Jkv=(Yt-mean(Yt))'* (Yt-mean(Yt));
mpev=mean(abs(ev./Yt));
ssev=ev'*ev;
MSv=ssev/(a-7);
R2v=1-(ssev/Jkv);

Hu=rbfDesign(Xu', M, SD, 'b');
lamb=globalRidge(Hu, Yu, 0.05);
Wu=inv(Hu'*Hu+lamb*eye(9))*Hu'*Yu;
%Wu=inv(Hu'*Hu*eye(9))*Hu'*Yu;
ftu=Hu*Wu;
eu=Yu-ftu;
Jku=(Yu-mean(Yu))'* (Yu-mean(Yu));
mpeu=mean(abs(eu./Yu));
sseu=eu'*eu;
MSu=sseu/(a-8);
R2u=1-(sseu/Jku);

MAPE=[mpe mpev mpeu];
SS=[sse ssev sseu];
MSt=[MS MSv MSu];
R2=[R2t R2v R2u];

Yh=[ft;ftv];
plot(Yu,'r');
hold on
plot(Yh, 'b');
legend('data asli','data hasil peramalan')
```

RIWAYAT HIDUP



Muhammad Ahnaf Zufar lahir di Lamongan pada tanggal 16 Juli 1995. Biasa dipanggil Zufar. Ia tinggal di Sumberjo, Somowinangun Karangbinangun Lamongan. Ia merupakan anak pertama dari bapak Yusuf Amrullah dan ibu Chayatun.

Pendidikan dasarnya ditempuh di MI Al Hidayah Meluke dan lulus pada tahun 2007. Kemudian melanjutkan sekolah tingkat pertama di MTsN Model Babat (MTsN 1 Lamongan) dan lulus pada tahun 2010. Sekolah tingkat atas ditempuh di MAN Lamongan (MAN 1 Lamongan) selama 3 tahun, dan selanjutnya menempuh kuliah di Universitas Islam Negeri Maulana Malik Ibrahim Malang pada tahun 2013.



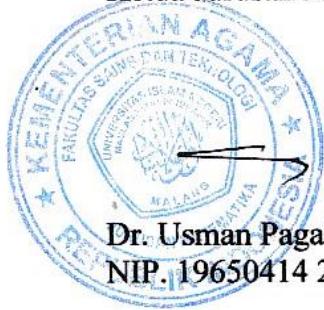
**KEMENTERIAN AGAMA RI
UNIVERSITAS ISLAM NEGERI
MAULANA MALIK IBRAHIM MALANG
FAKULTAS SAINS DAN TEKNOLOGI
Jl. Gajayana No. 50 Dinoyo Malang Telp./Fax.(0341)558933**

BUKTI KONSULTASI SKRIPSI

Nama : Muhammad Ahnaf Zufar
NIM : 13610022
Fakultas/Jurusan : Sains dan Teknologi/Matematika
Judul Skripsi : Perbandingan Metode ARIMA dengan RBFNN dalam Peramalan Rata-rata Banyaknya Bilangan *Sunspot*
Pembimbing I : Mohammad Jamhuri, M.Si
Pembimbing II : Dr. H. Imam Sudjarwo, M.Pd

No	Tanggal	Hal	Tanda Tangan
1	23 Februari 2017	Konsultasi Bab I	1. <i>(Signature)</i>
2	20 April 2017	Konsultasi Kajian Keagamaan Bab I dan Bab II	2. <i>(Signature)</i>
3	9 Mei 2017	Konsultasi Bab I dan Bab II	3. <i>(Signature)</i>
4	10 Mei 2017	Revisi Kajian Keagamaan Bab I dan Bab II	4. <i>(Signature)</i>
5	9 Agustus 2017	Konsultasi Bab III dan Bab IV	5. <i>(Signature)</i>
6	15 Agustus 2017	Revisi Bab I, Bab II, Bab III dan Bab IV	6. <i>(Signature)</i>
7	23 Agustus 2017	Konsultasi Bab V	7. <i>(Signature)</i>
8	28 Agustus 2017	Konsultasi Seluruh Bab	8. <i>(Signature)</i>
9	8 September 2017	Konsultasi Kajian Keagamaan Bab IV	9. <i>(Signature)</i>
10	14 September 2017	Revisi Kajian Keagamaan Bab IV	10. <i>(Signature)</i>
11	2 Oktober 2017	ACC Keseluruhan	11. <i>(Signature)</i>
12	2 Oktober 2017	ACC Kajian Keagamaan Keseluruhan	12. <i>(Signature)</i>

Malang, 24 April 2018
Mengetahui,
Ketua Jurusan Matematika



Dr. Usman Pagalay, M.Si
NIP. 19650414 2003 12 1 001