PROYEK AKHIR – VS191801

PERAMALAN CURAH HUJAN DI STASIUN JUANDA MENGGUNAKAN METODE ARIMA *BOX-JENKINS* DAN *RADIAL BASIS FUNCTION NEURAL NETWORK*

Ocktalia Trisnawati
NRP. 10611710000039

Pembimbing
Mike Prastuti, S.Si., M.Si

Program Studi Sarjana Terapan
Departemen Statistika Bisnis
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember
Surabaya 2021

PROYEK AKHIR – VS191801

PERAMALAN CURAH HUJAN DI STASIUN JUANDA MENGGUNAKAN METODE ARIMA *BOX-JENKINS* DAN *RADIAL BASIS FUNCTION NEURAL NETWORK*

Ocktalia Trisnawati
NRP. 10611710000039

Pembimbing
Mike Prastuti, S.Si., M.Si

Program Studi Sarjana Terapan
Departemen Statistika Bisnis
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember
Surabaya 2021

FINAL PROJECT – VS191801

FORECASTING OF RAINFALL AT JUANDA STATION USING ARIMA *BOX-JENKINS* AND *RADIAL BASIS FUNCTION NEURAL NETWORK* METHOD

Ocktalia Trisnawati
NRP. 10611710000039

Supervisor
Mike Prastuti, S.Si., M.Si

Study Program of Applied Undergraduate
Department of Business Statistics
Faculty of Vocations
Institut Teknologi Sepuluh Nopember
Surabaya 2021

LEMBAR PENGESAHAN

PERAMALAN CURAH HUJAN DI STASIUN JUANDA MENGGUNAKAN METODE ARIMA *BOX-JENKINS* DAN *RADIAL BASIS FUNCTION NEURAL NETWORK*

PROYEK AKHIR

Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Terapan Statistika
Pada Departemen Statistika Bisnis
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember

Oleh :
Ocktalia Trisnawati
10611710000039

SURABAYA, Agustus 2021

Menyetujui,
Pembimbing Tugas Akhir

Mike Prastuti, S.Si., M.Si
NIP. 19910122 201504 2 002

Mengetahui,
Kepala Departemen Statistika Bisnis
Fakultas Vokasi ITS

Dr. Wahyu Wibowo, S.Si., M.Si
NIP. 19740328 199802 1 001

PERAMALAN CURAH HUJAN DI STASIUN JUANDA MENGGUNAKAN METODE ARIMA *BOX-JENKINS* DAN *RADIAL BASIS FUNCTION NEURAL NETWORK*

Nama Mahasiswa : Ocktalia Trisnawati
NRP : 10611710000039
Program Studi : Sarjana Terapan
Departemen : Statistika Bisnis
Pembimbing : Mike Prastuti, S.Si., M.Si

Abstrak

Curah hujan yang tinggi tak hanya menyebabkan penundaan penerbangan, namun juga membuat pesawat terlambat mendarat karena menunggu cuaca sedikit lebih baik agar dapat dilakukan pendaratan dengan aman, terlebih lagi jika sering terjadi hujan maka akan membuat landasan pacu pesawat menjadi licin dan mengurangi jarak pandang pengelihatan. Dalam upaya untuk menghindari adanya kecelakaan pesawat, maka perlu dilakukan peramalan curah hujan agar dapat digunakan sebagai peringatan dini bagi maskapai penerbangan. Pada penelitian ini dilakukan peramalan curah hujan di Stasiun BMKG Juanda menggunakan metode ARIMA *Box-Jenkins* dan *Radial Basis Function Neural Network* (RBFNN). Tujuan dari penelitian ini adalah untuk mendapatkan model peramalan terbaik dengan membandingkan hasil ramalan model ARIMA dan RBFNN serta mendapatkan hasil peramalan curah hujan di Stasiun BMKG Juanda untuk beberapa periode kedepan. Data yang digunakan adalah data sekunder yang diperoleh dari BMKG Juanda Surabaya dari Januari 2019 hingga April 2021. Hasil penelitian ini menujukkan bahwa nilai MSE model RBFNN dengan 12 *neuron input*, 3 *neuron* lapisan tersembunyi, dan 1 *neuron output* sebesar 5.270, yaitu lebih kecil daripada MSE model ARIMA ([1,9,12,35,55,58]1,1) sehingga dapat disimpulkan bahwa metode RBFNN merupakan metode terbaik yang digunakan untuk meramalkan curah hujan di Stasiun Juanda.

Kata Kunci : *ARIMA Box-Jenkins, Curah Hujan, Juanda, Peramalan, RBFNN.*

FORECASTING OF RAINFALL AT JUANDA STATION USING ARIMA BOX-JENKINS AND RADIAL BASIS FUNCTION NEURAL NETWORK METHOD

Student Name : Ocktalia Trisnawati
NRP : 10611710000039
Program : Study Program of Applied Undergraduate
Departement : Business Statistics
Supervisor : Mike Prastuti, S.Si., M.Si

Abstract

Heavy rainfall not only causes flight delays, but also makes planes land late because they wait for slightly better weather to make a safe landing, especially if it rains frequently it will make the runway slippery and reduce visibility. In an effort to avoid aircraft accidents, it is necessary to forecast rainfall so that it can be used as an early warning for airlines. In this study, rainfall forecasting at BMKG Juanda Station was carried out using the Box-Jenkins ARIMA method and the Radial Basis Function Neural Network (RBFNN). The purpose of this study is to obtain the best forecasting model by comparing the forecast results of the ARIMA and RBFNN models and to obtain the results of forecasting rainfall at the BMKG Juanda Station for the next several periods. The data used is secondary data obtained from BMKG Juanda Surabaya from January 2019 to April 2021. The results of this study show that the MSE value of the RBFNN model with 12 input neurons, 3 hidden layer neurons, and 1 output neuron is 5,270, which is smaller than the MSE ARIMA model ([1,9,12,35,55,58]1,1) so it can be concluded that the RBFNN method is the best method used to predict rainfall at Juanda Station.

Keywords : *ARIMA BOX-Jenkins, Forecast, Juanda, Rainfall, RBFNN*

KATA PENGANTAR

Puji Syukur Kepada Allah SWT atas berkah dan rahmat-Nya, penulis dapat menyelesaikan laporan proyek akhir yang berjudul **"PERAMALAN CURAH HUJAN DI STASIUN JUANDA MENGGUNAKAN METODE ARIMA *BOX-JENKINS* DAN *RADIAL BASIS FUNCTION NEURAL NETWORK*".**

Laporan proyek akhir ini dapat terselesaikan dengan baik atas motivasi, bantuan, dan dukungan dari berbagai pihak secara langsung maupun tidak langsung. Pada kesempatan ini, penulis ingin mengucapkan terimakasih kepada :

1. Bapak Dr. Wahyu Wibowo, S.Si., M.Si selaku Kepala Departemen Statistika Bisnis Fakultas Vokasi ITS.
2. Ibu Mike Prastuti, S.Si., M.Si selaku dosen pembimbing yang senantiasa membimbing, member motivasi, kritik dan saran kepada penulis dalam menyusun laporan proyek akhir ini.
3. Bapak Dr. Brodjol Sutijo Suprih Ulama, S.Si., M.Si selaku dosen penguji proyek akhir yang telah memberi kritik dan saran demi kesempurnaan proyek akhir ini.
4. Ibu Ir. Sri Pingit Wulandari, M.Si selaku dosen penguji dan validator proyek akhir yang telah memberi kritik dan saran demi kesempurnaan proyek akhir ini.
5. Ibu Ir. Mutiah Salamah Chamid, M.Kes selaku dosen wali selama 8 semester yang telah membimbing baik akademik maupun non-akademik.
6. Dosen dan staff Departemen Statistika Bisnis yang membantu kelancaran proyek akhir.
7. Orang tua tercinta, Bapak Sutrisno dan Ibu Riatin yang telah memberi dukungan selama penulis menempuh pendidikan di ITS.
8. Angkatan 2017 (INFINITY) yang telah menemani hari-hari selama 8 semester hingga laporan proyek akhir ini selesai
9. Semua pihak yang telah membantu kelancaran penyusunan laporan proyek akhir ini.

Laporan proyek akhir ini masih banyak kekurangan baik secara materi maupun penulisan, oleh karena itu kritik dan saran sangat diperlukan untuk perbaikan laporan proyek akhir ini. Semoga laporan proyek akhir ini dapat memberi manfaat kepada pihak yang membutuhkan.

Surabaya, Agustus 2021

Penulis

DAFTAR ISI

Halaman

HALAMAN JUDUL i
TITLE PAGE iii
LEMBAR PENGESAHAN v
ABSTAK vii
ABSTRAC ix
KATA PENGANTAR xi
DAFTAR ISI xiii
DAFTAR TABEL xv
DAFTAR GAMBAR xvii
DAFTAR LAMPIRAN xix
BAB I PENDAHULUAN
1.1 Latar Belakang 1
1.2 Rumusan Masalah 3
1.3 Tujuan 4
1.4 Manfaat 4
1.5 Batasan Masalah 4
BAB II TINJAUAN PUSTAKA
2.1 ARIMA *Box-Jenkins* 5
2.1.1 Stasioneritas *Time Series* 5
2.1.2 Identifikasi Orde Model ARIMA 7
2.1.3 Estimasi Parameter 12
2.1.4 Pengujian Signifikansi Parameter 13
2.1.5 Cek Diagnosa Residual 14
2.1.6 Pemilihan Model Terbaik 15
2.2 Pengujian Linieritas 16
2.3 *Artificial Neural Network* (ANN) 17
2.3.1 Kerangka ANN 17
2.3.2 Arsitektur ANN 18
2.3.3 Metode Pembelajaran dan Pelatihan 19
2.3.4 *Radial Basis Function Neural Network* (RBFNN) 20
2.4 Curah Hujan 22

BAB III METODOLOGI PENELITIAN
3.1 Sumber Data 23
3.2 Variabel Penelitian 23
3.3 Langkah Analisis 24
3.4 Diagram Alir 25
BAB IV ANALISIS DAN PEMBAHASAN
4.1 Statistika Deskriptif Data Curah Hujan di Stasiun Juanda 27
4.2 Pemodelan Data Curah Hujan di Stasiun Juanda Menggunakan ARIMA *Box-Jenkins* 28
4.2.1 Identifikasi Stasioneritas Model ARIMA 28
4.2.2 Identifikasi Model ARIMA 32
4.2.3 Cek Diagnostik Residual *White Noise* dan Berdistribusi Normal 35
4.2.4 Pemilihan Model ARIMA Terbaik 37
4.3 Uji Linieritas Data Curah Hujan di Stasiun Juanda 39
4.4 Pemodelan Data Curah Hujan di Stasiun Juanda Menggunakan RBFNN 39
4.4.1 Penentuan Variabel *Input* 39
4.4.2 Penentuan Jaringan Optimum 40
4.5 Perbandingan Model ARIMA dan RBFNN 43
4.6 Peramalan Curah Hujan di Stasiun Juanda 43
BAB V KESIMPULAN DAN SARAN
5.1 Kesimpulan 47
5.2 Saran 47
DAFTAR PUSTAKA
LAMPIRAN
BIODATA PENULIS

DAFTAR TABEL

Halaman

Tabel 2.1 Nilai λ dan Transformasinya..... 7
Tabel 2.2 Struktur ACF dan PACF pada Model ARIMA 9
Tabel 3.1 Variabel Penelitian..... 23
Tabel 4.1 Statistika Deskriptif Data Curah Hujan di Stasiun Juanda..... 27
Tabel 4.2 Estimasi Parameter Model..... 32
Tabel 4.3 Cek Diagnostik Residual *White Noise* 35
Tabel 4.4 Cek Diagnostik Residual Berdistribusi Normal..... 36
Tabel 4.5 Pemilihan Model ARIMA Terbaik..... 37
Tabel 4.6 Uji Linieritas..... 39
Tabel 4.7 Penentuan Jaringan Optimum..... 40
Tabel 4.8 Perbandingan Kebaikan Model ARIMA dan RBFNN..... 43
Tabel 4.9 Ramalan Curah Hujan di Stasiun Juanda Periode 852-865..... 45

DAFTAR GAMBAR

Halaman

Gambar 2.1 Jaringan Lapisan Tunggal 18
Gambar 2.2 Jaringan Banyak Lapisan 19
Gambar 2.3 Jaringan Banyak Lapisan 19
Gambar 2.4 Arsitektur RBFNN 20
Gambar 3.1 Diagram Alir 26
Gambar 4.1 Plot *Box-Cox* Data Curah Hujan di Stasiun Juanda..... 28
Gambar 4.2 Plot *Box-Cox* Setelah Transformasi 29
Gambar 4.3 *Time Series* Plot Data Curah Hujan di Stasiun Juanda..... 30
Gambar 4.4 Plot ACF Data Curah Hujan 30
Gambar 4.5 Plot ACF Data Curah Hujan Setelah di *Differencing* 1..... 31
Gambar 4.6 Plot PACF Data Curah Hujan Setelah di *Differencing* 1..... 31
Gambar 4.7 *Boxplot* Residual. (a) ARIMA ([1,12,35,58],1, [1,50]), (b) ARIMA ([1,9,12,35,55,58],1,1), (c) ARIMA (1,1,1)..... 37
Gambar 4.8 *Time Series* Plot Data Aktual dan Nilai Ramalan Model ARIMA 40
Gambar 4.9 Arsitektur Jaringan RBFNN..... 41
Gambar 4.10 Data *Testing* (Aktual) dengan Nilai Ramalan Model RBFNN 44
Gambar 4.11 *Time Series* Plot Nilai Ramalan Model RBFNN..... 45

DAFTAR LAMPIRAN

Halaman

Lampiran 1. Data Curah Hujan di Stasiun Juanda 51
Lampiran 2. Perhitungan Data Hilang 52
Lampiran 3. Dugaan Model ARIMA..... 53
Lampiran 4. *Syntax* Estimasi Parameter 54
Lampiran 5. Estimasi Parameter Model ARIMA 54
Lampiran 6. Cek Diagnostik Residual *White Noise* 63
Lampiran 7. Cek Diagnostik Residual Berdistribusi Normal 66
Lampiran 8. Perhitungan Manual Pemilihan Model Terbaik ARIMA 67
Lampiran 9. Persamaan ARIMA ([1,9,12,35,55,58],1,1) 68
Lampiran 10. *Syntax* dan Hasil Uji Terasvirta..... 68
Lampiran 11. *Output Software* RBFNN 69
Lampiran 12. Surat Pernyataan Keaslian Data Curah Hujan di Stasiun Juanda 74

BAB I
PENDAHULUAN

1.1 Latar Belakang

Cuaca merupakan suatu kondisi udara di suatu tempat pada waktu yang relatif singkat, yang dinyatakan dengan nilai berbagai parameter seperti suhu, tekanan udara, kecepatan angin, kelembaban udara, dan berbagai fenomena atmosfer lainnya. Cuaca merupakan aspek penting dalam aktivitas penerbangan. Cuaca mempunyai dua aspek yaitu menguntungkan dan merugikan. Informasi cuaca berperan dalam peningkatan efisiensi dan efektivitas kegiatan dan keselamatan penerbangan seperti angin dan tekanan udara yang dapat dimanfaatkan untuk menetapkan jalur terpendek atau waktu terbang yang sependek mungkin (Maswir, 2013).

Keselamatan merupakan prioritas utama dalam sarana transprotasi khususnya bidang penerbangan. Keselamatan penerbangan berkaitan dengan banyak faktor diantaranya ada faktor manusia, faktor kondisi dan jenis pesawat terbang, fasilitas dan sarana bandar udara, fasilitas dan sarana telekomunikasi, dan faktor cuaca. Kemungkinan penyebab kecelakaan pesawat terbang 30% antara lain karena faktor cuaca, sedangkan 70% dari faktor manusia (Soerjadi, 2010).

Dalam dunia penerbangan, terdapat cuaca ekstrem yang mempunyai potensi membahayakan seperti curah hujan tinggi yang disertai angin kencang, gelombang gunung, dan *turbulence* didalam awan. Curah hujan tinggi mempengaruhi pendaratan dan lepas landas pesawat, telebih lagi jika sering terjadi hujan di bandara akan membuat landasan pacu menjadi licin dan mengurangi jarak pandang pengelihatan. Hal ini bisa menyebabkan penundaan penerbangan atau pesawat terlambat mendarat, karena pesawat menunggu cuaca sedikit lebih baik sehingga dapat dilakukan pendaratan dengan aman. Apabila cuaca tak kunjung membaik, maka akan dilakukan pendaratan di bandara terdekat atau kembali pada bandara pemberangkatan

Keberadaan awan di atsmosfer pada musim hujan akan memberikan goncangan pada pesawat terbang yang disebut dengan *turbulenci*.

Badan Meteorologi Klimatologi dan Geofisika (BMKG) Juanda mempunyai tugas melaksanakan fungsi BMKG di bidang Meteorologi khususnya untuk menunjang keselamatan transportasi udara. Selain itu, BMKG menyediakan informasi cuaca harian untuk beberapa kota di Jawa Timur. Berdasarkan informasi dari BMKG sebagian besar wilayah di Jawa Timur pada bulan November 2020 mulai memasuki musim hujan, dan Januari 2021 disebut-sebut sebagai puncak musim hujan sehingga keadaan cuaca dalam penerbangan sangatlah penting karena berhubungan dengan keselamatan baik penumpang maupun awak pesawat. (Suara Surabaya: 26 Januari 2021).

Dalam upaya untuk menghindari adanya kecelakaan pesawat, pemilihan metode yang tepat untuk menentukan kondisi cuaca seperti curah hujan adalah kegiatan yang akhir-akhir ini sering dilakukan oleh beberapa peneliti atmosfer atau cuaca. Hal ini dikarenakan banyaknya tuntutan dari berbagai pihak yang menginginkan informasi mengenai kondisi atmosfer yang lebih cepat, akurat, dan terperinci. Bahkan beberapa pihak lain menuntut tersedianya prediksi atau bahkan ramalan mengenai kondisi atmosfer dengan rentang waktu yang cukup pendek seperti waktu harian, jam, bahkan dalam waktu menit.

Pada data curah hujan selain terdapat pola linier diduga juga terdapat pola non-linier. Dalam pemodelan data yang berpola linier bisa digunakan metode ARIMA sedangkan untuk menangkap data yang berpola non-linier bisa digunakan model RBFNN. Metode ARIMA mengasumsikan data yang digunakan berhubungan secara linier yang sangat baik ketepatan akurasinya jika digunakan untuk peramalan jangka pendek, sedangkan kurang akurat untuk peramalan jangka panjang. RBFNN merupakan salah satu metode pada jaringan saraf tiruan yang terdiri dari lapisan input, lapisan tersembunyi, dan lapisan output. RBFNN memiliki ciri khas yaitu memiliki satu lapisan

tersembunyi dan mengeluarkan nilai berupa persamaan linier pada lapisan output yang membuat proses kerja RBFNN lebih cepat daripada jaringan saraf tiruan lainnya.

Penelitian sebelumnya tentang pemodelan curah hujan telah banyak dilakukan. Isnaini (2015) melakukan peramalan yang menghasilkan model ARIMA terbaik untuk pemodelan curah hujan di Cawak pada waktu ke-*t* akan dipengaruhi oleh besarnya curah hujan pada 1,36,37 dasahari sebelumnya sedangkan di Kedungadem besarnya curah hujan pada waktu ke-t akan dipengaruhi oleh besarnya curah hujan pada 1,36,37,53 dasahari sebelumnya. Penelitian lainnya tentang peramalan curah hujan dilakukan oleh Kristianda & Fithriasari (2016) dengan model VAR terbaik yaitu VARIMA (5,1,0) (0,1,0)[36], sedangkan untuk pemodelan VAR-NN yang terbaik adalah arsitektur jaringan dengan jumlah neuron pada input layer sebanyak 8, 2 neuron pada hidden layer, dan pada lapisan output sebanyak 2 neuron. Penelitian lainnya tentang curah hujan dilakukan oleh Novelia Purba (2016) dengan model RBFNN menghasilkan nilai *Mean Square Error* (MSE) sebesar 300,185, sementara model ARIMA menghasilkan nilai MSE sebesar 344,658. Berdasarkan perbandingan nilai MSE dari kedua model tersebut dinyatakan bahwa dalam penelitian ini model RBFNN lebih baik dibandingkan model ARIMA. Model RBFNN optimum adalah dengan 6 neuron pada input, 3 neuron pada lapisan tersembunyi, dan 1 neuron pada output.

1.2 Rumusan Masalah

Permasalahan dalam penelitian ini adalah curah hujan tinggi seringkali menunda banyak penerbangan dan memberi ancaman pada keselamatan penerbangan, sehingga dibutuhkan suatu metode untuk meramalkan curah hujan di Stasiun Juanda untuk beberapa periode selanjutnya. Beberapa penelitian sebelumnya menggunakan metode ARIMA dalam meramalkan data curah hujan, dimana hasil peramalan memiliki nilai error

yang cukup besar. Hal ini dikarenakan data curah hujan memiliki pola non-linier yang tidak dapat ditangkap oleh model ARIMA.

1.3 Tujuan Penelitian

Berdasarkan permasalahan yang muncul, maka tujuan dari penelitian ini adalah sebagai berikut.

1. Mendapatkan model terbaik peramalan curah hujan menggunakan model ARIMA
2. Mendapatkan model terbaik peramalan curah hujan menggunakan model RBFNN
3. Membandingkan hasil ramalan metode ARIMA dan RBFNN menggunakan kriteria kebaikan model
4. Mendapatkan hasil peramalan curah hujan untuk beberapa periode kedepan.

1.4 Batasan Masalah

Batasan masalah dalam penelitian ini adalah data curah hujan di Stasiun Juanda berupa data harian mulai Januari 2019 hingga April 2021. Pada model RBFNN menggunakan minimal 2 neuron lapisan tersembunyi.

1.5 Manfaat

Manfaat yang diperoleh dari penelitian ini adalah diharapkan dapat membantu pihak BMKG mendapatkan model peramalan yang lebih baik dari peramalan yang digunakan oleh BMKG saat ini dan memberikan informasi kepada maskapai penerbangan di Bandara Juanda terkait dengan peringatan dini aktivitas penerbangan terkait curah hujan yang akan terjadi.

BAB II
TINJAUAN PUSTAKA

2.1 ARIMA *Box-Jenkins*

Metode *time series* adalah suatu metode peramalan untuk masa depan yang dilakukan berdasarkan nilai atau data masa lalu dari suatu variabel dan kesalahan (*error*) masa lalu. Tujuan dari metode peramalan *time series* ini adalah untuk menemukan pola data *time series* (runtun waktu) dan mengekstrapolasikan pola tersebut ke masa depan.

Konsep *Autoregressive Integrated Moving Average* (ARIMA) pertama kali dikembangkan oleh George Box dan Gwilym Jenkins (1976). Keduanya mengembangkan model tersebut untuk analisis *time series.* Nama keduanya sering disinonimkan dengan proses ARIMA sehingga disebut juga sebagai metode ARIMA Box-Jenkins. ARIMA Box-Jenkins adalah gabungan dari *Autoregressive* (AR) dan *Moving Average* (MA) yang memerlukan proses *differencing* dengan mengubah runtun waktu nonstasioner dalam *mean* menjadi data yang stasioner dalam *mean.* Model ini mengabaikan variabel prediktor secara penuh dalam membuat peramalannya karena hanya menggunakan data variabel dependen masa lalu dan sekarang untuk menghasilkan ramalan jangka pendek yang akurat. Kelebihan model ini adalah sangat baik ketepatan akurasinya jika digunakan untuk peramalan jangka pendek, sedangkan kurang akurat untuk peramalan jangka panjang (Makridakis, 1999).

2.1.1 Stasioneritas *Time Series*

Stasioneritas *time series* adalah asumsi yang mendasari bahwa proses suatu deret pengamatan tidak berubah seiring dengan adanya perubahan waktu. Jika suatu *time series* Z_t stasioner, maka *mean* dan *varians* deret tersebut tidak dipengaruhi oleh berubahnya waktu pengamatan, sehingga proses ada dalam keseimbangan statistik. Dengan kata lain, data *time series* dapat dikatakan stasioner adalah relatif berfluktuasi konstan disekitar

mean. Suatu proses $\{Z_t\}$ dikatakan stasioner jika distribusi bersama dari $Z_{t_1}, Z_{t_2}, ..., Z_{t_n}$ dengan $Z_{t_1+1}, Z_{t_2+2}, ..., Z_{t_n+k}$ adalah sama pada setiap $t_1, t_2, ..., t_n$ dan semua waktu pada *lag-k*. Hal ini dapat menyebabkan nilai dari $E(Z_t) = E(Z_{t+k}) = \mu$ dan $Var(Z_t) = Var(Z_{t+k}) = \sigma^2$ pada setiap waktu *t* dan *lag-k* (Wei, 2006).

Seringkali *time series* tidak stasioner dalam *mean* akibat adanya pola seiring dengan perubahan waktu. Suatu deret yang nonstasioner dapat direduksi menjadi deret yang stasioner melalui *differencing* menggunakan operator *shift* mundur *(backward shift)* yang dinotasikan Δ^d atau dapat ditulis $(1-B)^d$ dengan

$$\Delta Z_t = Z_t - Z_{t-1} \tag{2.1}$$

Ketika data tidak stasioner dalam varians, dilakukan transformasi untuk menstabilkan varians atau membuat varians menjadi homogen. Salah satu tranformasi yang bisa digunakan adalah *Power Transformation*. Secara umum, *Power Transformation* diberikan sebagai berikut.

$$T(Z_t) = \begin{cases} \dfrac{Z_t^{\lambda} - 1}{\lambda} & ; \lambda \neq 0 \\ \ln Z_t & ; \lambda = 0 \end{cases} \tag{2.2}$$

untuk λ yang bernilai nol, maka dilakukan transformasi logaritma sebagai berikut.

$$\lim_{\lambda \to 0} T(Z_t) = \lim_{\lambda \to 0} \frac{Z_t^{\lambda} - 1}{\lambda} = \ln(Z_t) \tag{2.3}$$

dimana Z_t adalah pengamatan pada waktu ke-*t* dan λ adalah parameter yang digunakan untuk transformasi. Metode ini diperkenalkan oleh Box dan Cox (1994) di dalam Wei (2006). Berikut adalah nilai λ yang sering digunakan dan bentuk transformasinya.

Tabel 2.1 Nilai λ dan Transformasinya

Nilai λ	Transformasi
-1,0	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0,0	$ln\ Z_t$
0,5	$\sqrt{Z_t}$
1,0	Z_t *(Tidak perlu ditransformasi)*

Data dikatakan stasioner dalam varians apabila batas bawah dan batas atas dari transformasi *Box-Cox* memuat nilai λ=1, sebaliknya dikatakan tidak stasioner dalam varians apabila batas bawah dan batas atas tidak memuat angka 1. Stasioneritas data runtun waktu harus terpenuhi karena digunakan untuk membuat dan batas atas dari transformasi *Box-Cox* memuat nilai kesimpulan statistik tentang struktur proses stokastik berdasarkan catatan yang diamati dari proses tersebut (Cryer & Chan, 2008).

2.1.2 Identifikasi Orde Model ARIMA

Identifikasi model ARIMA menggunakan plot ACF dan PACF. Plot ACF digunakan untuk menduga orde *p* pada model *Autoregressive* (AR) dan plot PACF untuk menduga orde *q* pada model *Moving Average* (MA).

a. *Autocorrelation Function*

Autocorretaltion Function (*ACF*) digunakan untuk menujukkan hubungan linear antara Z_t dan Z_{t+k}. Suatu proses stationer $\{Z_t\}$ mempunyai nilai $E(Z_t)=\mu$ dan $Var(Z_t) = E(Z_t-\mu)^2=\sigma^2$, dimana nilai *mean* dan *varians* tersebut adalah konstan (Wei,2006). Persamaan dari kovarians antara Z_t dan Z_{t+k} ditunjukkan dalam Persamaan 2.4 sebagai berikut:

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

dan korelasi antara Z_t dan Z_{t+k} ditunjukkan dalam Persamaan 2.5 sebagai berikut:

$$\hat{\rho}_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \qquad (2.5)$$

dimana γ_k adalah fungsi autokovarian dan $\hat{\rho}_k$ adalah fungsi autokorelasi antara Z_t dengan Z_{t+k} dari proses yang sama dan hanya terpisah oleh *lag* waktu ke-*k*.

b. *Partial Autocorrelation Function*

Partial Autocorrelation Function (PACF) digunakan untuk mengukur tingkat keeratan hubungan antara pasangan data Z_t dengan Z_{t+k} setelah pengaruh variabel Z_{t+1}, $Z_{t+2,\ldots,}$ Z_{t+k-1} terhadap Z_{t+k} dihilangkan (Wei,2006). Korelasi ditunjukkan dalam Persamaan 2.6 sebagai berikut:

$$Corr(Z_t, Z_{t+k} \mid Z_{t+1}, \ldots, Z_{t+k-1}) \qquad (2.6)$$

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

$$\hat{Z}_{t+k} = \alpha_1 Z_{t+k-1} + \alpha_2 Z_{t+k-2} + \ldots + \alpha_{k-1} Z_{t+1} \qquad (2.7)$$

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

$$E(Z_{t+k} - \hat{Z}_{t+k})^2 = E(Z_{t+k} - \alpha_1 Z_{t+k-1} - \ldots - \alpha_{k-1} Z_{t+1})^2 \qquad (2.8)$$

Dengan cara yang sama,

$$\hat{Z}_t = \beta_1 Z_{t+1} + \beta_2 Z_{t+2} + \ldots + \beta_{k-1} Z_{t+k-1} \qquad (2.9)$$

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

$$E(Z_t - \hat{Z}_t)^2 = E(Z_t - \beta_1 Z_{t+k-1} - \ldots - \beta_{k-1} Z_{t+k-1})^2 \qquad (2.10)$$

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

$$\phi_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^{k} \phi_{kj}\hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^{k} \phi_{kj}\hat{\rho}_j} \tag{2.11}$$

dengan $\hat{\phi}_{k+1,k+1} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1}\hat{\phi}_{k,k+1-j}$ dan $j = 1,2,\ldots,k$

c. Orde Model ARIMA

Identifikasi model ARIMA dilakukan setelah data stationer dengan melihat pola ACF dan PACF. Pendugaan model dilakukan dengan memperhatikal hal-hal yang tertera dalam Tabel 2.2

Tabel 2.2 Struktur ACF dan PACF pada Model ARIMA

Model	ACF	PACF
Autoregressive (p)	Turun eksponensial	Terpotong setelah *lag-p*
Moving Average (q)	Terpotong setelah *lag-q*	Turun eksponensial
Autoregressive Moving Average (p,q)	Turun eksponensial	Turun eksponensial

1. Model *Autoregressive*

Model AR *(Autoregressive)* pada orde *p* menyatakan bahwa suatu model dimana pengamatan waktu ke-*t* berhubungan linear dengan pengamatan waktu sebelumnya *t-1, t-2,…,t-p.* Bentuk fungsi persamaan untuk model AR pada orde *p* ditunjukkan dalam Persamaan 2.12

$$\begin{aligned}
&\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \ldots + \phi_p \dot{Z}_{t-p} + a_t \\
&\dot{Z}_t - \phi_1 B \dot{Z}_{t-1} - \ldots - \phi_p B^p \dot{Z}_{t-p} = a_t \\
&\left(1 - \phi_1 B - \phi_2 B^2 - \ldots - \phi_p B^p\right)\dot{Z}_t = a_t \\
&\phi_p(B)\dot{Z}_t = a_t
\end{aligned} \tag{2.12}$$

dimana,

$$\dot{Z}_t = Z_t - \mu \tag{2.13}$$

Keterangan:

Z_t = nilai aktual pada waktu ke-*t*

ϕ_p = parameter *autoregressive* ke-*p*

a_t = nilai residual pada saat ke-*t*

μ = suatu konstanta

2. Model *Moving Average*

Model MA *(Moving Average)* digunakan untuk menjelaskan suatu fenomena bahwa suatu observasi pada waktu *t* dinyatakan sebagai kombinasi linear dari sejumalah error acak. Bentuk fungsi persamaan untuk model MA pada orde *q* ditunjukkan dalam Persamaan 2.14

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \ldots - \theta_q a_{t-q} \tag{2.14}$$

atau bisa disederhanakan dalam Persamaan 2.15

$$\dot{Z}_t = \theta_q(B) a_t \tag{2.15}$$

dimana,

$$\theta_q(B) = 1 - \theta_1 B - \ldots - \theta_q B^q \tag{2.16}$$

Keterangan:

Z_t = nilai aktual pada waktu ke-*t*

θ_q = parameter *Moving Average* ke-*q*

a_t = nilai residual pada saat ke-*t*

3. Model *Autoregressive Moving Average*

Model ARMA merupakan model gabungan antara model AR dan MA yang biasanya ditulis ARMA *(p,q)*. Bentuk fungsi model ARMA pada orde *p* dan *q* dinyatakan dalam Persamaan 2.17

$$\begin{aligned}
&\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \ldots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \ldots - \theta_q a_{t-q} \\
&\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \ldots + \phi_p \dot{Z}_{t-p} = a_t - \theta_1 a_{t-1} - \ldots - \theta_q a_{t-q} \\
&\dot{Z}_t - \phi_1 B\dot{Z}_{t-1} - \ldots - \phi_p B^p \dot{Z}_{t-p} = a_t - \theta_1 B a_{t-1} - \ldots - \theta_q B^q a_{t-q} \\
&\left(1 - \phi_1 B - \phi_2 B^2 - \ldots - \phi_p B^p\right)\dot{Z}_t = (1 - \theta_1 B - \ldots - \theta_q B^q) a_t \\
&\phi_p(B)\dot{Z}_t = \theta_q(B) a_t
\end{aligned} \tag{2.17}$$

4. Model *Integrated Autoregressive Moving Average*

Model ARIMA merupakan model *time series* yang tidak stationer terhadap *mean* dan memerlukan proses *differencing* agar stationer. Persamaan ARIMA *(p,d,q)* dapat dituliskan dalam Persamaan 2.18

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B) a_t \tag{2.18}$$

Model ARIMA musiman dinotasikan dengan ARIMA $(P,D,Q)^S$ dapat dituliskan dalam Persamaan 2.19

$$\Phi_p(B^S)(1-B^S)^D Z_t = \Theta_Q + (B^S) a_t \tag{2.19}$$

Model ARIMA multiplikatif dinotasikan dengan ARIMA *(p,d,q)* $(P,D,Q)^S$ yang mempunyai faktor regular dan musiman pengamatan waktu ke-*t*. Bentuk fungsi persamaan model ARIMA multiplikatif ditunjukkan dalam Persamaan 2.20

$$\Phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\Theta_Q(B^S) a_t \tag{2.20}$$

Keterangan:

B = operator *back shift*

Φ_P = parameter ke-P dari model AR musiman

Θ_Q = parameter ke-Q dari model MA musiman

$\theta_q(B)$ = $(1-\theta_1 B-\theta_2 B-\ldots-\theta_p B^p)$ polinomial MA orde q

Z_t = nilai aktual pada waktu ke-t

ϕ_p = parameter ke-p dari model *autoregressive*

θ_q = parameter ke-q dari model *moving average*

a_t = nilai residual pada saat ke-t

$\Phi_P(B^S)$ = $(1-\Phi_1 B^s-\Phi_2 B^{2s}-\ldots-\Phi_P B^{ps})$ polinomial AR musiman orde p

$\Theta_q(B^S)$ = $(1-\Theta_1 B^s-\Theta_2 B^{2s}-\ldots-\Theta_P B^{ps})$ polinomial MA musiman orde q

$(1-B^S)^D$ = *differencing* musiman s dengan D adalah orde *differencing*

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

2.1.3 Estimasi Parameter

Setelah dilakukan identifikasi model ARIMA, tahap selanjutnya yaitu estimasi parameter model. Salah satu metode yang sering digunakan adalah metode *Conditional Least Squares* (Cryer, 2008).Metode ini dilakukan dengan cara mencari nilai parameter meminimumkan jumlah kuadrat *error*.

Misalkan model yang terbentuk model AR (1) yaitu $Z_t-\mu=\phi(Z_{t-1}-\mu)+a_t$. Model ini dapat dilihat sebagai suatu model regresi dengan variabel peramal atau prediktor Z_{t-1} dan variabel respon Z_t. Maka *least square estimation* dinyatakan dalam bentuk Persamaan 2.21

$$S(\phi,\mu)=\sum_{i=2}^{n} a_t^2=\sum_{i=2}^{n}[(Z_t-\mu)-\emptyset(Z_{t-1}-\mu)]^2 \qquad (2.21)$$

Berdasarkan prinsip dari metode *Conditional Least Squares*, penaksiran ϕ dan μ dengan meminimumkan $S(\phi,\mu)$. Hal ini dilakukan dengan menurunkan $S(\phi,\mu)$ terhadap μ dan ϕ

kemudian disamakan dengan nol. Meminimumkan $S(\phi,\mu)$ terhadap μ menghasilkan Persamaan 2.22

$$\frac{\partial S}{\partial \mu} = \sum_{i=2}^{n} 2[(Z_t - \mu) - \phi(Z_{t-1} - \mu)](-1 + \phi) = 0 \qquad (2.22)$$

Maka diperoleh nilai taksiran parameter untuk μ dari model AR(1) ditunjukkan pada Persamaan 2.23

$$\hat{\mu} = \frac{\sum_{i=2}^{n} Z_t - \phi \sum_{i=2}^{n} Z_{t-1}}{(n-1)(1-\phi)} \qquad (2.23)$$

Nilai n yang besar dapat ditulis menggunakan Persamaan 2.24

$$\sum_{i=2}^{n} \frac{Z_t}{n-1} \approx \sum_{i=2}^{n} \frac{Z_{t-1}}{n-1} \approx \bar{Z} \qquad (2.24)$$

Sehingga Persamaan 2.24 dapat disederhanakan dalam bentuk Persamaan 2.25

$$\hat{\mu} \approx \frac{\bar{Z} - \phi\bar{Z}}{1-\phi} = \bar{Z} \qquad (2.25)$$

Menggunakan cara yang sama, operasi turunan terhadap ϕ ditunjukkan pada Persamaan 2.26

$$\frac{\partial S}{\partial \phi} = -\sum_{i=2}^{n} 2[(Z_t - \bar{Z}) - \phi(Z_{t-1} - \bar{Z})](Z_{t-1} - \bar{Z}) = 0 \qquad (2.26)$$

Sehingga didapatkan nilai taksiran pada Persamaan 2.27

$$\hat{\phi} = \frac{\sum_{i=2}^{n} (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{i=2}^{n} (Z_{t-1} - \bar{Z})^2} \qquad (2.27)$$

Berdasarkan Persamaan 2.25 dan Persamaan 2.27 merupakan nilai taksiran untuk parameter μ dan ϕ (Cryer, 2008).

Estimasi parameter untuk model MA dengan CLS adalah $S(\mu,\theta) = \sum_{i=1}^{n} a_t^2(\eta, \theta, Zinit, ainit, Z)$ dengan $\sigma_a^2 = S(\mu,\theta)/db$. *Zinit*, *ainit* merupakan nilai inisialisasi awal dan *db=n-(p+q-1).* $S(\mu,\theta)$ merupakan suatu fungsi non-linear dengan parameter yang tidak diketahui sehingga diperlukan suatu iterasi non-linear untuk mendapatkan parameternya.

2.1.4 Pengujian Signifikansi Parameter

Pengujian signifikansi parameter dilakukan untuk mengetahui apakah hasil penaksiran parameter model ARIMA signifikan atau tidak, sehingga dapat diketahui apakah tiap variabel yang digunakan berpengaruh pada Z_t. pengujian hipotesis

dilakukan dengan menggunakan uji-*t* dengan hipotesis sebagai berikut (Bowerman & O'Connell, 1993)

Hipotesis Model AR:

$H_0 : \phi_p = 0$ (parameter AR tidak signifikan terhadap model)

$H_1 : \phi_p \neq 0$ (parameter AR signifikan terhadap model)

Statistik uji untuk model AR ditunjukkan pada persamaan 2.28 berikut :

$$t_{hitung} = \frac{\hat{\phi}_p}{SE(\hat{\phi}_p)} \tag{2.28}$$

dengan nilai $SE(\hat{\phi}_p) = \frac{Z_{1-\alpha/2}}{\sqrt{n}}$

Hipotesis Model MA:

$H_0 : \theta_q = 0$ (parameter MA tidak signifikan terhadap model)

$H_1 : \theta_q \neq 0$ (parameter MA signifikan terhadap model)

Statistik uji untuk model MA ditunjukkan pada persamaan 2.29 berikut :

$$t_{hitung} = \frac{\hat{\theta}_q}{se(\hat{\theta}_q)} \tag{2.29}$$

dengan nilai $SE(\hat{\theta}_p) = \sqrt{\frac{1 + 2\sum_{j}^{k-1} \hat{\rho}_j^2}{n}}$

Daerah penolakan adalah tolak H_0 jika $\left|t_{hitung}\right| > t_{\alpha/2, n-p}$ atau tolak H_0 jika $P_{value} < \alpha$ dengan α adalah taraf signifikansi, p adalah banyaknya parameter AR, q adalah banyaknya parameter MA, $se(\hat{\beta})$ adalah standar error dari nilai taksiran ϕ atau θ.

2.1.5 Cek Diagnosa Residual

Pemeriksaan asumsi residual digunakan untuk mengetahui kesesuaian model dari parameter-parameter yang signifikan berdasarkan kriteria residual yang memenuhi asumsi *white noise* dan berdistribusi normal.

a. Residual *White Noise*

White noise merupakan asumsi dimana gangguan pada residual telah dihilangkan. Jika residual model telah memenuhi asumsi *white noise*, berarti residual tersebut saling independen dan identik. Pemeriksaan asumsi residual *white noise* dilakukan dengan Uji *Ljung-Box* dengan hipotesis sebagai berikut (Wei, 2006)

$H_0 : \rho_1 = \rho_2 = ... = \rho_K = 0$

H_1 : minimal ada satu $\rho_j \neq 0$, dengan $j=1,2,...,K$

Statistik uji yang digunakan sebagai berikut

$$Q = n(n+2)\sum_{k=1}^{K}(n-k)^{-1}\hat{\rho}_k^2 \qquad (2.30)$$

keterangan:

n = banyaknya pengamatan

$\hat{\rho}_k$ = autokorelasi lag ke-k

K = jumlah lag maksimum

Statistik uji Q mengikuti distribusi $\chi^2_{(K-m)}$ dimana $m=p+q$. H_0 akan ditolak jika $Q > \chi^2_{\alpha,(K-m)}$ atau tolak H_0 jika $P_{value} < \alpha$. Apabila residual model tidak *white noise* maka dilakukan *overfitting* model hingga didapatkan model yang memenuhi asumsi tersebut.

b. Residual Berdistribusi Normal

Selanjutnya akan dilakukan pemeriksaan diagnostik dengan pengujian asumsi residual berdistribusi normal dengan Uji *Kolmogorov-Smirnov* dengan hipotesis sebagai beri

$H_0 : F_n(x) = F_0(x)$ (residual memenuhi asumsi distribusi normal)

$H_1 : F_n(x) \neq F_0(x)$ (residual tidak memenuhi asumsi distribusi normal)

Statistik uji yang digunakan adalah sebagai berikut.

$$D = \max\left|F(x) - F_0(x)\right| \tag{2.31}$$

keterangan:

$F(x)$ = nilai peluang kumulatif residual

$F_0(x)$ = nilai peluang kumulatif distribusi normal

H_0 akan ditolak jika nilai $D > D_{(1-\alpha),n}$ atau tolak H_0 jika $P_{value} < \alpha$, dimana *n* sebagai derajat bebasnya.

2.1.6 Pemilihan Model Terbaik

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

$$MSE = \frac{1}{n}\sum_{t=1}^{n}\left|Z_t - \hat{Z}_t\right|^2 \tag{2.32}$$

2.2 Uji Linearitas

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

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

$$Z_t = f_t + \hat{e}_t \tag{2.33}$$

2. Meregresikan $\hat{e}_t$ pada 1, Z_{t-1}, $Z_{t-2,\ldots,}$ Z_{t-p} dan kemudian menghitung jumlah kuadrat nilai residual $SSR_1 = \Sigma \hat{v}_t^2$.
3. Menghitung nilai statistik uji sebagai berikut

$$F_{hitung} = \frac{\left(SSR_0 - SSR_1\right)/m}{SSR_1/\left(n - p - 1 - m\right)} \tag{2.34}$$

Keterangan :
p = prekdiktor awal
m = prediktor tambahan (m=2)
n = jumlah pengamatan
$\hat{v}_t$ = residual ke-t
SSR = Sum Square Residual
Hipotesis yang digunakan adalah sebagai berikut
H_0 : model linier
H_1 : model nonlinier
Statistik uji-F mengikuti distribusi $F_{(\alpha,m,(n-p-1-m))}$. H_0 ditolak jika nilai $F_{hitung} > F_{(\alpha,m,(n-p-1-m))}$ atau nilai $P_{value} < \alpha$.

2.3 *Artificial Neural Network*

Artificial Neural Network (ANN) atau Jaringan Syaraf Tiruan adalah sistem komputasi dimana arsitektur dan operasi diilhami dari pengetahuan tentang sel syaraf didalam otak dan merupakan model yang meniru cara kerja jaringan *neural* biologis. ANN merupakan salah satu contoh model non linier yang memiliki bentuk fungsional fleksibel dan mengandung beberapa parameter yang tidak dapat diinterpretasikan seperti pada model parametrik namun hal inilah yang membuat ANN mampu menyelesaikan persoalan yang tidak terstruktur dan sulit didefinisikan (Zhang, 2004).

2.3.1 Kerangka ANN

Pada ANN, *neuron-neuron* akan dikumpulkan dalam lapisan-lapisan *(layer)* yag disebut *neuron layer*. Pada umumnya *neural network* mempunyai tiga macam lapisan, yaitu

1. Lapisan *Input (Input Layer)*
   Node-node dalam lapisan *input* disebut *neuron-neuron input*. *Neuron-neuron input* menerima *input* berupa gambaran suatu permasalan dari luar.
2. Lapisan Tersembunyi *(Hidden Layer)*
   Node-node dalam lapisan tersembunyi disebut *neuron-neuron* tersembunyi.
3. Lapisan *Output (Output Layer)*
   Node-node dalam lapisan *output* disebut *neuron-neuron output*. Keluaran dari lapisan ini merupakan hasil dari *neural network* terhadap suatu permasalahan.

2.3.2 Arsitektur ANN

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

1. Jaringan Lapisan Tunggal *(Single Layer Net)*
   Jaringan dengan lapisan tunggal memiliki satu lapisan dengan bobot-bobot terhubung. Jaringan ini hanya menerima *input* kemudian secara langsung akan mengolahnya menjadi *ouput* tanpa harus melalui lapisan lain (lapisan tersembunyi). Dengan kata lain, ciri-ciri dari arsitektur jasingan saraf lapisan tunggal adalah hanya terdiri dari satu lapisan *input* dan satu lapisan *ouput*. Pada jaringan lapisan tunggal hanya terdapat satu jenis pembobot. Contoh arsitektur jaringan dengan lapisan tunggal dapat dilihat pada Gambar 2.1

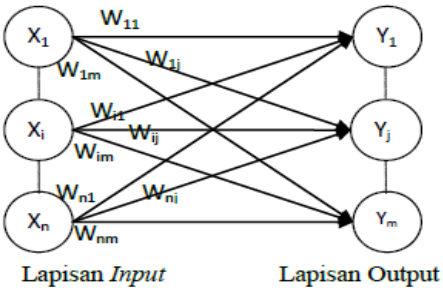

Gambar 2.1 Jaringan Lapisan Tunggal (Purba,2016)

2. Jaringan Banyak Lapisan *(Multilayer Net)*
   Jaringan dengan banyak lapisan memiliki satu atau lebih lapisan yang berada di antara lapisan *input* dan lapisan *ouput* (terdapat satu atau lebih lapisan tersembunyi). Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih sulit dibanding dengan jaringan dengan lapisan tunggal. Contoh arsitektur jaringan banyak lapisan dapat dilihat pada Gambar 2.2

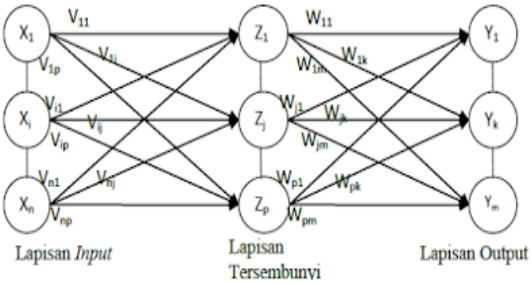

Gambar 2.2 Jaringan Banyak Lapisan (Purba,2016)

3. Jaringan Lapisan Kompetitif *(Competitive Layer Net)*
   Bentuk lapisan kompetitif merupakan jaringan saraf tiruan yang sangat besar. Interkoneksi antar neuron pada lapisan ini tidak ditunjukkan pada arsitektur seperti jaringan yang lain. Pada jaringan ini sekumpulan neuron bersaing untuk mendapatkan hak menjadi aktif atau sering pula disebut dengan prinsip *winner takes all* atau yang menanglah yang

mengambil semua bagiannya. Contoh arsitektur jaringan lapisan kompetitif dapat dilihat pada Gambar 2.3

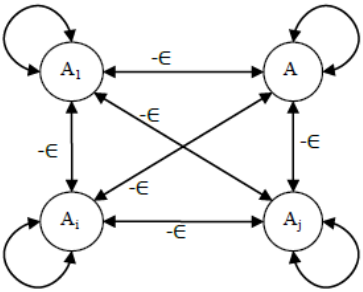

Gambar 2.3 Jaringan Banyak Lapisan (Purba,2016)

2.3.3 Metode Pembelajaran dan Pelatihan

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

1. Pembelajaran Terawasi (*supervised learning)*
   Pada proses pembelajaran ini, satu *input* yang telah diberikan pada satu *neuron* di lapisan *input* akan dijalankan di sepanjang jaringan saraf sampai ke *neuron* pada lapisan *ouput*. Hasil *ouput* yang diperoleh kemudian dicocokkan dengan target. Jika *error* yang didapat cukup besar, akan dilakukan pembelajaran yang lebih banyak lagi.
2. Pembelajaran Tidak Terawasi (un*supervised learning*)
   Pada proses pembelajaran ini, nilai bobot disusun dalam suatu interval atau range tertentu, tergantung pada *input* yang diberikan. Pembelajaran ini bertujuan mengelompokkan unit-unit yang hampir sama dalam satu area tertentu.

2.3.4 *Radial Basis Function Neural Network*

Radial Basis Function Neural Network (RBFNN) memiliki 3 *layer*, yaitu *input layer*, *hidden layer*, dan *output layer*. Arsitektur jaringan RBFNN dijelaskan pada Gambar 2.4

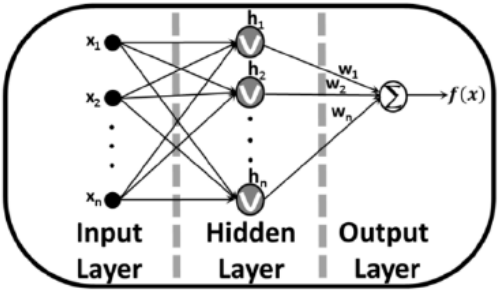

Gambar 2.4 Arsitektur RBFNN (Purba,2016)

Output di rumuskan sebagai berikut

$$\hat{y} = \sum_{j=1}^{m} w_j h_j(x) + w_0 \tag{2.35}$$

fungsi aktivasi dengan RBFNN dinyatakan sebagai berikut

$$h_j(x) = \exp\left(-\sum_{i=1}^{k} \left(\frac{\left\| x_i - c_j \right\|^2}{2\sigma_j^2} \right) \right) \tag{2.36}$$

dimana,

$$\sigma_j = \sqrt{\frac{1}{P} \sum_{p=1}^{P} \sigma_{jp}^2} \tag{2.37}$$

w_j = parameter pada node ke-*j*

h_j = fungsi aktivasi pada node ke-*j*

c_j = vektor *center* pada node ke-*j*

σ_j = standar deviasi pada node ke-*j*

x = vektor *input*

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

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

1. Menetukan koordinat titik tengah *(centeroid)* setiap cluster,
2. Menentukan jarak setiap objek terhadap koordinat titik tengah. Misalkan terdapat sebanyak *k* variabel *input* dan sebanyak *n* pasangan data, sehingga terbentuk matriks *input* $\boldsymbol{X}_{nxk.}$ *Cluster* yang akan dibentuk adalah sebanyak *g*, sehingga terdapat matrik titik pusat $\boldsymbol{C}_{gxk..}$ perhitungan jarak setiap pasangan data terhadap titik pusat dihitung dengan rumus pada persamaan 2.34

$$d(x_l, c_j) = \sqrt{\sum_{i=1}^{k} \left(x_{li}, c_{ji}\right)^2} \qquad (2.38)$$

   dimana,
   x = vektor *input*
   c = nilai *center*
   i = indeks variabel *(1,2,..,k)*
   j = indeks kelompok *(1,2,…,g)*
   l = indeks pasangan data *(1,2,…,n)*
3. Mengelompokkan objek-objek tersebut berdasarkan pada jarak minimumnya ke titik pusat.

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

2.4 Curah Hujan

Curah hujan adalah butir-butir air atau kristal es yang jatuh/keluar dari awan atau kelompok awan. Banyaknya curah hujan yang mencapai permukaan bumi atau tanah selama selang waktu tertentu dapat diukur dengan jalan mengukur tinggi air hujan dengan cara tertentu. Hasil dari pengukuran dinamakan curah hujan, yaitu tanpa mengingat macam atau bentuk pada saat mencapai permukaan bumi dan tidak memperhitungkan endapan yang meresap ke dalam tanah, hilang karena penguapan, atau pun mengalir (Swarinoto, 2011).

BAB III
METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari BMKG Juanda Surabaya *www.dataonline.bmkg.go.id* dengan unit penelitian curah hujan harian mulai Januari 2019 hingga April 2021 sebanyak 851 data. Surat pernyataan keaslian data curah hujan di Stasiun Juanda dapat dilihat pada Lampiran 12. Data curah hujan ini akan dibagi menjadi dua, yaitu data *in-sample* dan data *out-sample.* Data *in-sample* dimulai dari Januari 2019 hingga Desember 2020 (731 data) dan data *out-sample* dimulai dari Januari 2021 hingga April 2021 (120 data).

3.2 Variabel Penelitian

Variabel yang digunakan pada penelitian ini akan ditampilkan pada Tabel 3.1

Tabel 3.1 Variabel Penelitian

Tahun	Bulan	Tanggal	Curah Hujan (mm)
2019	Januari	1	Z_1
		2	Z_2
	:	:	:
	Desember	1	Z_{32}
		2	Z_{33}
		:	:
		31	Z_{365}
:	:	:	:
2021	Januari	1	Z_{732}
		2	Z_{733}
	:	:	:
	April	1	Z_{822}
		:	:
		30	Z_{851}

3.3 Langkah Analisis

Langkah-langkah yang digunakan dalam menganalisis data, yaitu langkah analisis dengan metode ARIMA *Box-Jenkins* dan metode RBFNN akan dijelaskan sebagai berikut.

1. Melakukan *pre-processing* data curah hujan di Stasiun Juanda
2. Mendapatkan karakteristik data curah hujan di Stasiun BMKG Juanda menggunakan statistika deskriptif
3. Melakukan peramalan curah hujan menggunakan metode ARIMA *Box-Jenkins*, berikut adalah langkah-langkah yang akan dilakukan
   a. Membuat *time series* plot pada data *in-sampel* untuk melakukan identifikasi pola *time series* pada data curah hujan
   b. Melakukan identifikasi stasioneritas data, yaitu stasioner terhadap varian dan stasioner terhadap *mean.* Jika tidak stasioner terhadap varian maka akan dilakukan transformasi *Box-Cox*, dan jika tidak stasioner terhadap *mean* akan dilakukan *differencing*
   c. Membuat plot ACF dan PACF untuk melihat pola data
   d. Identifikasi dan pendugaan model ARIMA berdasarkan pada plot ACF dan PACF.
   e. Estimasi parameter dan pengujian signifikansi parameter
   f. Pengujian asumsi residual *white noise* dan berdistribusi normal pada model yang terbentuk
   g. Mendapatkan model peramalan terbaik menggunakan kriteria MSE.
4. Melakukan peramalan curah hujan menggunakan metode RBFNN, berikut adalah langkah-langkah yang akan dilakukan
   a. Menentukan variabel *input* dengan melihat plot PACF dari data *training*. Variabel input ditentukan oleh *lag-lag* yang nilai PACF-nya signifikan

b. Menentukan nilai pusat dengan menggunakan metode klaster *k-means* dan menghitung nilai varian dari hasil pengelompokan
c. Menentukan jaringan yang optimum dengan jaringan yang memiliki nilai MSE terekecil

5. Memilih model peramalan terbaik berdasarkan model ARIMA dan RBFNN menggunakan nilai MSE
6. Melakukan peramalan curah hujan untuk beberapa periode kedepan dengan model yang terbaik.

3.4 Diagram Alir Penelitian

Langkah analisis yang akan dilakukan dalam penelitian ini akan disajikan dalam diagram alir pada Gambar 3.1

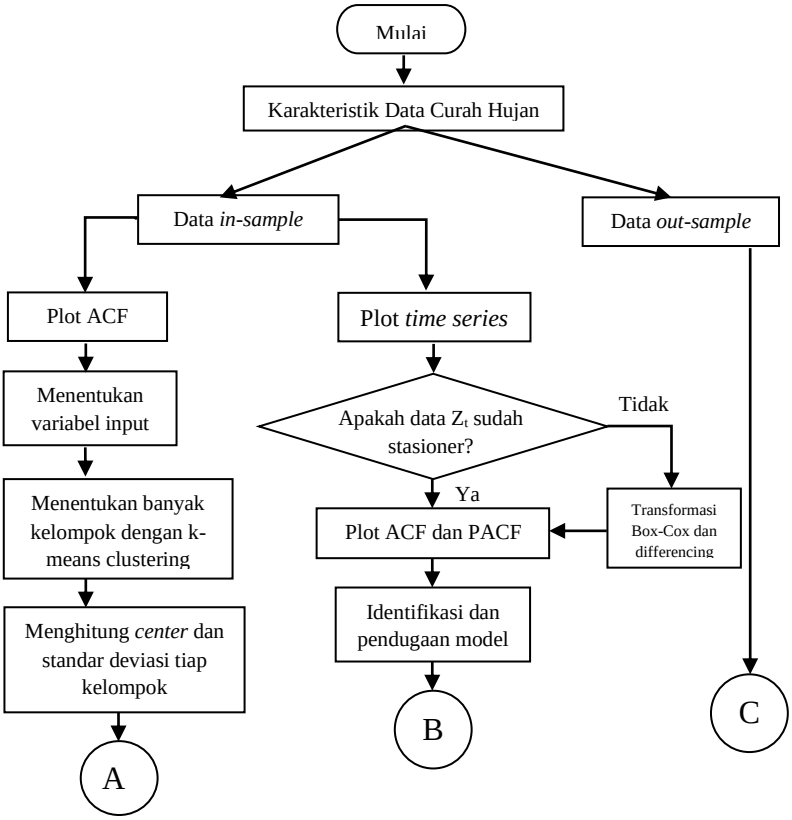

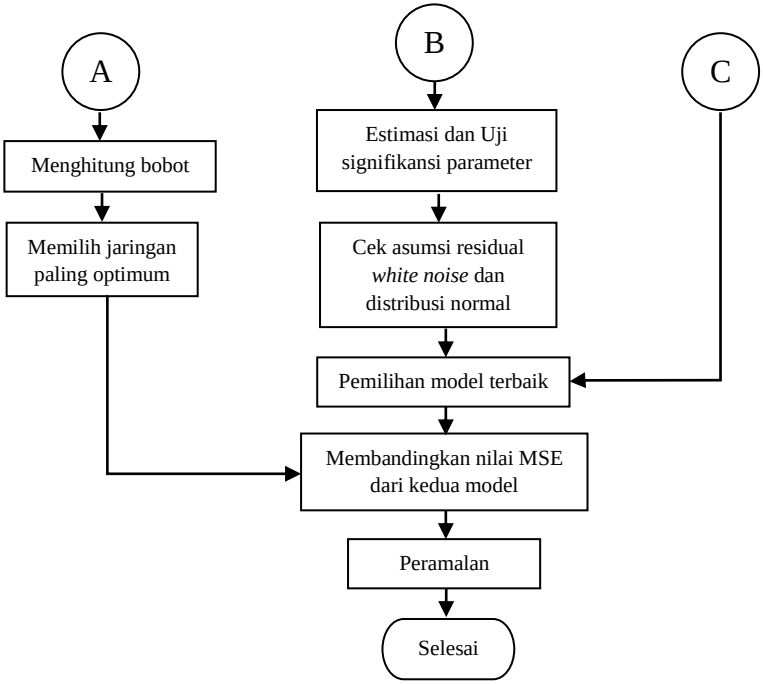

Gambar 3.1 Diagram Alir Penelitian

BAB IV
ANALISIS DAN PEMBAHASAN

Bab ini akan membahas tentang hasil penelitian data curah hujan di Stasiun Juanda. Data curah hujan ini akan diramalkan dengan metode ARIMA *Box-Jenkins* dan *Radial Basis Function Neural Netrowk* (RBFNN).

4.1 Statistika Deskriptif Data Curah Hujan di Stasiun Juanda

Data yang digunakan merupakan data harian yang kemudian akan dilakukan *pre-processing* data dengan imputasi terhadap data kosong, dari 851 data ada sekitar 52 data yang kosong dan penambahan nilai 1 pada semua data agar tidak ada data yang bernilai nol.

Pada data asli terdapat nilai-nilai curah hujan yang hilang karena tidak dilakukan pengukuran pada hari itu, sehingga perlu dilakukan imputasi data. Metode imputasi data yang digunakan adalah dengan mencari nilai rata-rata pada tanggal yang sama dari tahun 2015-2018 (4 tahun), perhitungan data hilang dapat dilihat pada Lampiran 2. Pemilihan 4 tahun di latar belakangi oleh adanya pola musiman yang dapat terlihat minimal setiap 2 tahun selain itu pemilihan metode rata-rata pada tanggal yang sama karena curah hujan pada bulan tertentu tidak jauh berbeda pada tahun sebelumnya.

Berdasarkan data curah hujan di Stasiun Juanda pada Lampiran 1 diperoleh hasil statistika deskriptif yang dijelaskan pada Tabel 4.1

Tabel 4.1 Statistika Deskriptif Data Curah Hujan di Stasiun Juanda

Tahun	Rata-Rata	Varians	Minimum	Maksimum
2019	5.439	227.651	0	156.600
2020	8.666	314.553	0	127.700
2021*	12.510	316.710	0	89.800

*) Tahun 2021 hanya sampai bulan April

Tabel 4.1 menjelaskan bahwa Tahun 2019 curah hujan maksimum sebanyak 156.600 mm (03 Februari) dengan keragaman data sebesar 227.651. Tahun 2020 curah hujan maksimum sebanyak 127.700 mm (01 Februari) dengan keragaman data sebesar 314.553. Tahun 2021 curah hujan maksimum sebanyak 89.800 mm (08 Januari) dengan keragaman data sebesar 316.710. Pada Tahun 2019 tidak hujan terjadi 252 hari dari 365 hari, Tahun 2020 tidak hujan terjadi 168 hari dari 366 hari, dan tahun 2021 tidak hujan terjadi 27 hari dari 120 hari.

4.2 Pemodelan Data Curah Hujan di Stasiun Juanda Menggunakan ARIMA Box-Jenkins

Data yang digunakan dalam penelitian ini sebanyak 851 data. Data *in-sample* sebanyak 731 akan digunakan untuk membangun model ARIMA. Sedangkan 120 data sebagai *out-sample* yang akan digunakan untuk menguji kebaikan model.

4.2.1 Identifikasi Stasioneritas Model ARIMA

Tahap awal pendugaan model ARIMA adalah memeriksa stasioneritas data terhadap *varians* dan *mean* karena model ARIMA mengasumsikan bahwa data yang digunakan stasioner dalam *varians* dan *mean.* Data curah hujan ada yang bernilai nol artinya hari tersebut tidak hujan maka semua data curah hujan terlebih dahulu ditambah nilai 1 agar dapat diperiksa stasioneritas dalam *varians* dengan *box-cox plot*. Lebih jelasnya akan dilakukan estimasi parameter menggunakan *box-cox* (λ) dapat dilihat pada Gambar 4.1

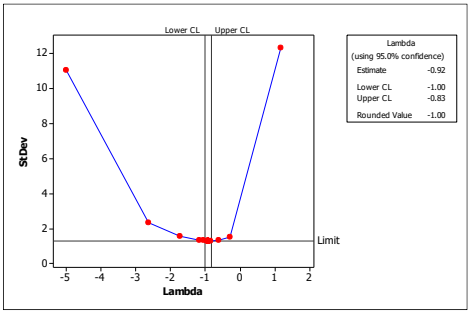

Gambar 4.1 Plot *Box-Cox* Data Curah Hujan di Stasiun Juanda

Gambar 4.1 menjelaskan hasil plot *box-cox* data curah hujan di Stasiun Juanda memiliki nilai λ tidak sama dengan 1, serta batas atas dan batas bawah tidak melewati nilai 1 sehingga dapat disimpulkan data curah hujan di Stasiun Juanda belum stasioner dalam *varians*. Nilai λ yang diperoleh sebesar -1,00 sehingga data akan di transformasi dengan $T(Z_t) = {}^{1}\!/_{Z_t}$. Hasil transformasi *box-cox* dapat dilihat pada Gambar 4.2

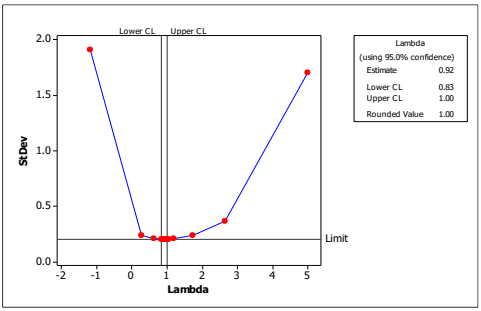

Gambar 4.2 Plot *Box-Cox* Setelah Transformsi

Gambar 4.2 menujukkan hasil plot *box-cox* data curah hujan di Stasiun Juanda setelah transformasi diketahui nilai *rounded value* (λ) sebesar 1, serta batas atas dan batas bawah telah melewati nilai 1 sehingga dapat disimpulkan bahwa data telah stasioner dalam varians.

Selanjutnya akan dilakukan pemeriksaan stasioneritas dalam *mean* yang dapat dilihat dari *time series plot* dan Plot ACF. *Time series plot* data curah hujan di Stasiun Juanda dapat dilihat pada Gambar 4.3

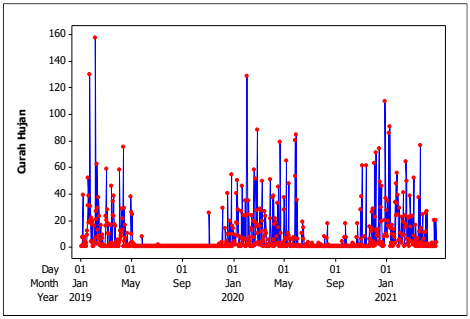

Gambar 4.3 Plot *Time Series* Data Curah Hujan di Stasiun Juanda

Gambar 4.3 menujukkan plot *time series* data curah hujan di Stasiun Juanda tidak stasioner dalam *mean*, yang terlihat dari fluktuasi data tidak stabil, tetapi akan dilakukan pengecekan melalui plot ACF agar lebih jelas. Plot ACF dapat dilihat pada Gambar 4.4

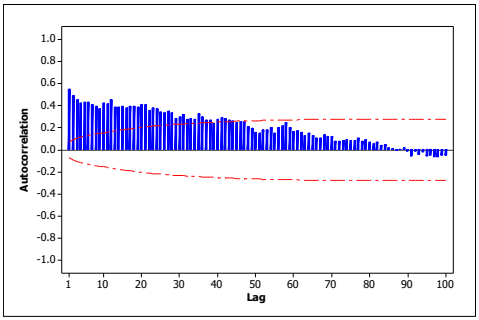

Gambar 4.4 Plot ACF Data Curah Hujan

Gambar 4.4 menujukkan bahwa pada plot ACF turun lambat sehingga dapat dikatakan data curah hujan di Stasiun Juanda belum stasioner dalam *mean*. Data yang tidak stasioner dalam *mean* perlu dilakukan *differencing* (d=1) agar stasioner dalam *mean*. Plot ACF dan PACF hasil *differencing* data dapat dilihat pada Gambar 4.5 dan Gambar 4.6

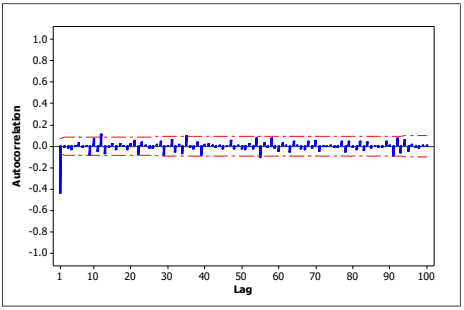

Gambar 4.5 Plot ACF Data Curah Hujan Setelah di *Differencing* 1

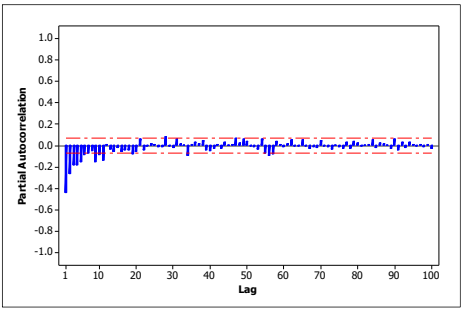

Gambar 4.6 Plot PACF Data Curah Hujan Setelah di *Differencing* 1

Berdasarkan Gambar 4.5 dapat diketahui bahwa plot ACF *cut off* pada lag ke-1 sehingga dapat disimpulkan data sudah stasioner dalam *mean.* Setelah data sudah stasioner dalam *varians* dan *mean*, maka langkah selanjutnya adalah mengidentifikasi orde model ARIMA.

4.2.2 Identifikasi Model ARIMA

Identifikasi model ARIMA dapat menggunakan plot ACF dan PACF. Plot ACF digunakan untuk menduga model MA dan plot PACF digunakan untuk menduga model AR. Gambar 4.5 dan Gambar 4.6 menujukkan bahwa plot ACF *cut off* pada *lag-1* dan plot PACF turun secara eksponensial, sehingga dugaan model ARIMA yang diperoleh dapat dilihat secara lengkap pada Lampiran 3.

Dalam proses mengetahui model yang tepat digunakan akan dilakukan estimasi parameter untuk setiap model dugaan dengan *syntax* estimasi parameter pada Lampiran 4. Hasil estimasi parameter ditunjukkan pada Tabel 4.2 dan secara lengkap dapat dilihat pada Lampiran 5

Tabel 4.2 Estimasi Parameter Model

No	Model	Estimasi Parameter	Nilai Koefisien	SE	Thitung	Pvalue
1	ARIMA (6,1,0)	$\hat{\phi}_1$	-0.676	0.037	-18.260	<.0001
		$\hat{\phi}_2$	-0.494	0.044	-11.220	<.0001
		$\hat{\phi}_3$	-0.388	0.046	-8.390	<.0001
		$\hat{\phi}_4$	-0.319	0.046	-6.890	<.0001
		$\hat{\phi}_5$	-0.211	0.044	-4.780	<.0001
		$\hat{\phi}_6$	-0.087	0.037	-2.350	0.019
2	ARIMA ([9,10,11, 28,34,56],1 ,0)	$\hat{\phi}_9$	-0.080	0.043	-1.860	0.063
		$\hat{\phi}_{10}$	0.016	0.048	0.350	0.729
		$\hat{\phi}_{11}$	-0.046	0.043	-1.060	0.288
		$\hat{\phi}_{28}$	0.051	0.038	1.350	0.178
		$\hat{\phi}_{34}$	-0.077	0.038	-2.020	0.044
		$\hat{\phi}_{56}$	0.034	0.039	0.870	0.385
3	ARIMA ([9,11,28, 34,56],1,0)	$\hat{\phi}_9$	-0.087	0.037	-2.340	0.020
		$\hat{\phi}_{11}$	-0.053	0.037	-1.420	0.157
		$\hat{\phi}_{28}$	0.051	0.038	1.350	0.178
		$\hat{\phi}_{34}$	-0.076	0.038	-2.010	0.045
		$\hat{\phi}_{56}$	0.034	0.039	0.870	0.382

Tabel 4.2 Estimasi Parameter Model (Lanjutan)

No	Model	Estimasi Parameter	Nilai Koefisien	SE	Thitung	Pvalue
4	ARIMA ([9,11,28, 34],1,0)	$\hat{\phi}_9$	-0.085	0.037	-2.290	0.023
		$\hat{\phi}_{11}$	-0.054	0.037	-1.430	0.152
		$\hat{\phi}_{28}$	0.052	0.038	1.390	0.166
		$\hat{\phi}_{34}$	-0.079	0.038	-2.090	0.037
5	ARIMA ([9,11,34], 1,0)	$\hat{\phi}_9$	-0.087	0.037	-2.350	0.019
		$\hat{\phi}_{11}$	-0.052	0.037	-1.390	0.165
		$\hat{\phi}_{34}$	-0.077	0.038	-2.040	0.041

Tabel 4.2 menujukkan bahwa dari 33 model yang diduga didapatkan 15 model dengan parameter yang signifikan. Selanjutnya, dari 15 model yang signifikan akan dilakukan pemeriksaan residual *white noise* untuk menentukan model yang lebih baik.

4.2.3 Cek Diagnostik Residual *White Noise* dan Berdistribusi Normal

Cek diagnostik residual *white noise* dan berdistribusi normal dilakukan untuk menyatakan bahwa model ARIMA yang digunakan mampu mewakili pola data. Cek diagnostik residual *white noise* menggunakan uji *Ljung-Box*. Nilai residual dari model ARIMA dinyatakan *white noise* ketika nilai autokorelasi tidak signifikan atau P_{value} > 0,05. Secara lengkap hasil cek diagnostik residual *white noise* dapat dilihat pada Lampiran 6. Dari 15 dugaan model ARIMA (Tabel 4.2) diperoleh 3 model ARIMA dengan residual *white noise* dapat dilihat pada Tabel 4.3

Tabel 4.3 Cek Diagnostik Residual *White Noise*

No	Model	Lag	Q	df	Pvalue	Keputusan
1	ARIMA ([1,12,35,58],1,[1,50]	12	9.660	6	0.140	White Noise
		18	13.230	12	0.353	
		24	22.860	18	0.196	
		30	28.730	24	0.231	
		36	34.430	30	0.264	
		42	41.130	36	0.256	
		48	43.230	42	0.419	
2	ARIMA ([1,9,12,35,55,58],1,1)	12	6.550	5	0.256	White Noise
		18	9.680	11	0.559	
		24	19.850	17	0.282	
		30	25.740	23	0.314	
		36	30.720	29	0.379	
		42	37.030	35	0.376	
		48	40.380	41	0.498	
3	ARIMA (1,1,1)	6	2.680	4	0.613	White Noise
		12	17.390	10	0.066	
		18	19.700	16	0.234	
		24	28.580	22	0.157	
		30	33.770	28	0.209	
		36	43.780	34	0.122	
		42	50.920	40	0.116	
		48	54.730	46	0.177	

Selanjutnya akan dilakukan cek diagnostik residual berdistribusi normal menggunakan uji *Kolmogorov Smirnov* secara lengkap dapat dilihat pada Lampiran 7 dan disajikan pada Tabel 4.4

Tabel 4.4 Cek Diagnostik Residual Berdistribusi Normal

No	Model	D	P_{value}	Keputusan
1	ARIMA ([1,12,35,58],1,[1,50])	0.117924	<0.0100	Tidak Berdistribusi Normal
2	ARIMA ([1,9,12,35,55,58],1,1)	0.125679	<0.0100	Tidak Berdistribusi Normal
3	ARIMA (1,1,1)	0.16327	<0.0100	Tidak Berdistribusi Normal

Tabel 4.4 menujukkan bahwa residual dari ketiga model tidak berdistribusi normal, hal ini terlihat dari nilai $P_{value} < 0{,}05$. Oleh karena itu, akan dilakukan cek *outlier* untuk melihat penyebab residual tidak berdistribusi normal. Hasil cek *outlier* dapat dilihat pada Gambar 4.7

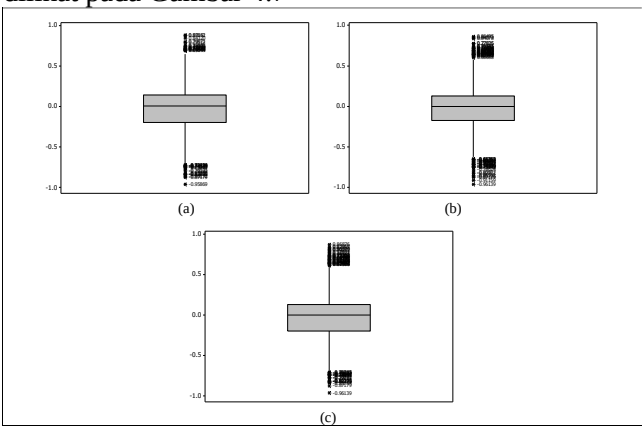

Gambar 4.7 *Boxplot* Residual. (a) ARIMA ([1,12,35,58],1,[1,50]), (b) ARIMA ([1,9,12,35,55,58],1,1), (c) ARIMA (1,1,1)

Gambar 4.7 menujukkan bahwa *boxplot* residual dari ketiga model memiliki banyak data yang *outlier*, hal ini menyebabkan residual tidak berdistribusi normal.

4.2.4 Pemilihan Model ARIMA Terbaik

Pemilihan model ARIMA terbaik menggunakan kriteria MSE dengan melihat nilai MSE terkecil yang diperoleh dari data *out-sample*. Secara lengkap hasil perhitungan manual pemilihan model terbaik ARIMA dapat dilihat pada Lampiran 8. Hasil dari pemilihan model ARIMA terbaik dapat dilihat pada Tabel 4.5

Tabel 4.5 Pemilihan Model ARIMA Terbaik

No	Model ARIMA	MSE
1	ARIMA ([1,12,35,58],1,[1,50])	39.828
2	ARIMA ([1,9,12,35,55,58],1,1)	**16.902**
3	ARIMA (1,1,1)	20.191

Tabel 4.5 menujukkan hasil pemilihan model terbaik berdasarkan kriteria kebaikan model yang digunakan, yaitu MSE. Model ARIMA ([1,9,12,35,55,58],1,1) menghasilkan nilai MSE terkecil.

Persamaan matematis yang dibangun oleh model ARIMA ([1,9,12,35,55,58],1,1) dapat dilihat pada Persamaan 4.1 dan uraian secara lengkap dapat dilihat pada Lampiran 9

$$\begin{aligned}\hat{Z}_t &= 1{,}146Z_{t-1} - 0{,}146Z_{t-2} - 0{,}074Z_{t-9} + 0{,}074Z_{t-10} \\ &+ 0{,}084Z_{t-12} - 0{,}084Z_{t-13} + 0{,}082Z_{t-35} - 0{,}082Z_{t-36} \\ &- 0{,}081Z_{t-55} + 0{,}081Z_{t-56} + 0{,}122Z_{t-58} - 0{,}122Z_{t-59} \\ &+ a_t - 0{,}878a_{t-1}\end{aligned} \tag{4.1}$$

Berdasarkan Persamaan 4.1 dapat diketahui bahwa peramalan curah hujan di Stasiun Juanda pada periode ke-*t* akan dipengaruhi oleh curah hujan satu periode sebelumnya, dua periode sebelumnya, sembilan periode sebelumnya, sepuluh periode sebelumnya, dua belas periode sebelumnya, tiga belas periode sebelumnya, tiga puluh lima periode sebelumnya, tiga puluh enam periode sebelumnya, lima puluh lima periode sebelumnya, lima puluh enam periode sebelumnya, lima puluh delapan periode sebelumnya, dan lima puluh Sembilan periode sebelumnya.

Visualisasi data *out-sampel* dengan nilai ramalan model ARIMA ([1,9,12,35,55,58],1,1) dapat dilihat pada Gambar 4.8

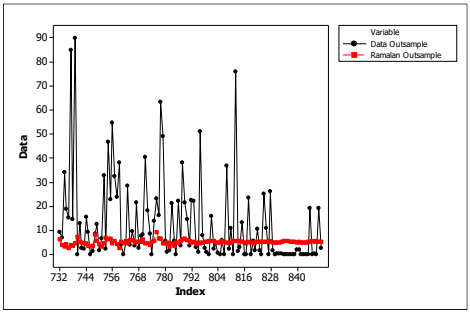

Gambar 4.8 *Time Series* Plot Data Aktual dan Nilai Ramalan Model ARIMA

Gambar 4.8 menujukkan bahwa nilai ramalan cenderung bergerak stabil disekitar data *out-sampel* terlihat dari *time series plot* yang dihasilkan.

4.3 Uji Linearitas

Uji linearitas digunakan untuk mengatahui apakah data terdapat pola linear atau non-linear. Uji linearitas yang digunakan adalah uji terasvirta. Hasil uji terasvirta data curah hujan di Stasiun Juanda dapat dilihat pada Tabel 4.6. *Syntax* dan hasil uji terasvirta secara lengkap dapat dilihat pada Lampiran 10

Tabel 4.6 Uji Linearitas

F_{hitung}	$F_{0,05;2;848}$	P_{value}
20,212	3,006	0,000

Tabel 4.6 menujukkan hasil uji terasvirta data curah hujan di Stasiun Juanda. Dengan taraf signifikan α(0,05) dan tolak H_0 jika $F_{hitung} > F_{(\alpha,df1,df2)}$ atau nilai $P_{value} < \alpha$, didapatkan nilai F_{hitung} sebesar 20,212 lebih besar dari $F_{0,05;2;848}$ sebesar 3,006 dan diperkuat dengan P_{value}(0,000) lebih kecil dari α(0,05) maka diputuskan tolak H_0 yang artinya data curah hujan di Stasiun Juanda berpola non-linear.

4.4 Pemodelan Data Curah Hujan di Stasiun Juanda Menggunakan RBFNN

Dalam pemodelan data curah hujan di Stasiun Juanda menggunakan RBFNN akan dilakukan pembagian data *training* sebesar 90% untuk membentuk model dan data *testing* sebesar 10% untuk menguji kebaikan model.

4.4.1 Penentuan Variabel Input

Data *training* yang berjumlah 766 yang digunakan untuk membangun model jaringan RBFNN merupakan data harian curah hujan di Stasiun Juanda. Langkah pertama untuk membentuk model adalah menentukan matrik *input* yang terdiri dari variabel-variabel *input*. Variabel *input* ditentukan oleh nilai *partial autokorelasi* yang signifikan.

Pada pemilihan model terbaik ARIMA didapatkan nilai *partial autokorelasi* ada 12 *lag* yang signifikan, berarti ada 12 variabel input dalam model RBFNN. Variabel input yang akan digunakan, yaitu Z_{t-1}, Z_{t-2}, Z_{t-9}, Z_{t-10}, Z_{t-12}, Z_{t-13}, Z_{t-35}, Z_{t-35}, Z_{t-55}, Z_{t-56}, Z_{t-58}, *dan* Z_{t-59}. Dalam penelitian ini terdapat 12 buah neuron pada lapisan input, karena banyak variabel *input* sama dengan banyaknya *neuron*.

4.4.2 Penentuan Jaringan Optimum

Penentuan jaringan optimum ditentukan oleh variabel *input* yang kemudian akan dikelompokkan dengan metode *k-means cluster*. Penentuan banyaknya kelompok akan dilakukan dengan cara *trial and error*, yaitu mengelompokkan data *training* kedalam 2 kelompok, 3 kelompok, 4 kelompok, 5 kelompok, dan 6 kelompok.

Dari semua kelompok yang dicobakan, akan dipilih satu kelompok terbaik dengan melihat kriteria kebaikan model, yaitu dengan MSE terkecil. Berdasarkan *output software* RBFNN pada Lampiran 11, hasil penentuan jaringan optimum dapat dilihat pada Tabel 4.7

Tabel 4.7 Penentuan Jaringan Optimum

Banyak Kelompok	**MSE**	
	Training	***Testing***
2	85473.982	9546.458
3	85462.214	**9538.503**
4	85510.244	9544.602
5	85484.277	9540.051
6	85499.508	9544.391

Tabel 4.7 menujukkan hasil penentuan jaringan optimum yang terpilih adalah 3 kelompok karena memiliki nilai MSE terkecil. Sehingga model RBFNN yang digunakan dapat dibentuk dengan arsitektur 12 *neuron* pada lapisan input, 3 *neuron* pada lapisan tersembunyi, dan 1 *neuron* pada lapisan output.

Pembobot yang digunakan pada jaringan RBFNN untuk curah hujan di Stasiun Juanda adalah sebagai berikut

$$C = \begin{bmatrix} 0.032 & 3.924 & 10.903 \\ 0.055 & 3.759 & 10.948 \\ 0.028 & 3.780 & 10.739 \\ 0.013 & 4.152 & 10.574 \\ 0.020 & 1.106 & 11.166 \\ 0.029 & 0.445 & 11.255 \\ 0.034 & 0.495 & 11.446 \\ 0.038 & 0.997 & 11.258 \\ 0.059 & 0.549 & 11.227 \\ 0.022 & 1.380 & 11.108 \\ 0.042 & 1.401 & 11.067 \\ 0.060 & 0.820 & 11.205 \end{bmatrix}$$

$$\Sigma = \begin{bmatrix} 0.337 & 8.560 & 28.583 \end{bmatrix}$$

w_0 = 13.435 ; w_1 = -1.497 ; w_2 = -10.746 ; w_3 = -12.352

Arsitektur jaringan RBFNN dapat dilihat pada Gambar 4.9

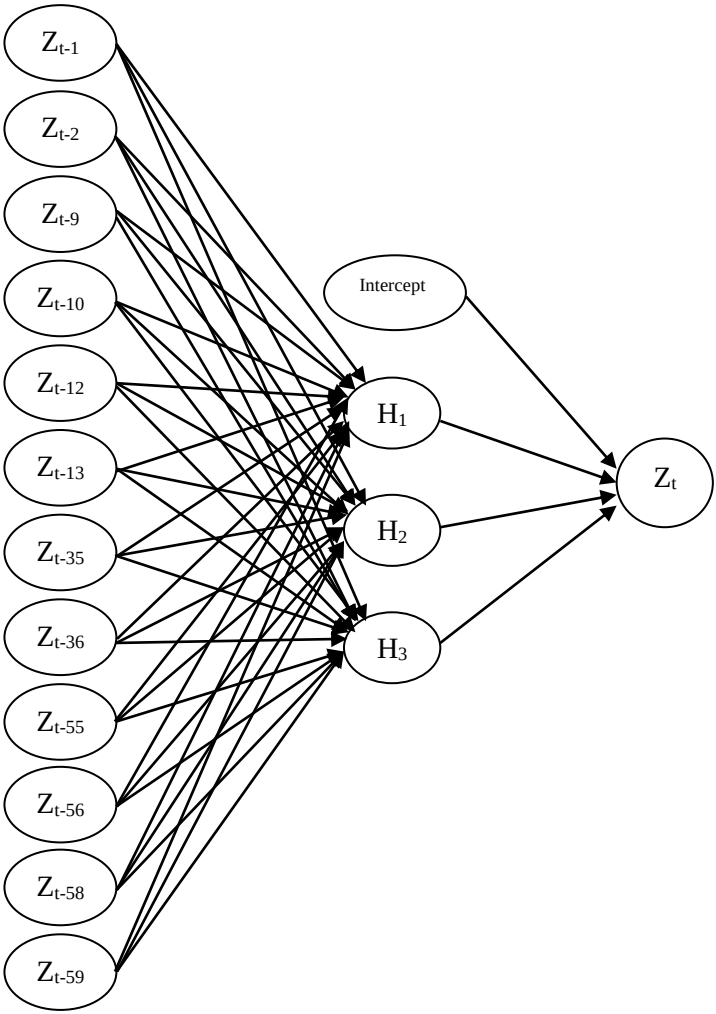

Gambar 4.9 Arsitektur Jaringan RBFNN

Berdasarkan arsitektur jaringan RBFNN curah hujan di Stasiun Juanda pada Gambar 4.9 dan *output* pada Lampiran 11, maka model yang terbentuk seperti pada Persamaan 4.2

$$\hat{Z}_t = 13.435 - 1.497 h_1(x) - 10.746 h_2(x) - 12.352 h_3(x) \qquad (4.2)$$

dengan nilai $h_j(x)$ sebagai berikut

$$h_j(x) = \exp\left\{ - \left[\frac{(x_1 - c_{1j})^2}{2\sigma_j^2} + \frac{(x_2 - c_{2j})^2}{2\sigma_j^2} + \ldots + \frac{(x_{12} - c_{12j})^2}{2\sigma_j^2} \right] \right\} \qquad (4.3)$$

Berdasarkan Persamaan 4.2, akan dilakukan validasi model dengan meramalkan data *testing* yang digunakan. Visualisasi data *testing* dengan nilai ramalan model RBFNN dapat dilihat pada Gambar 4.10

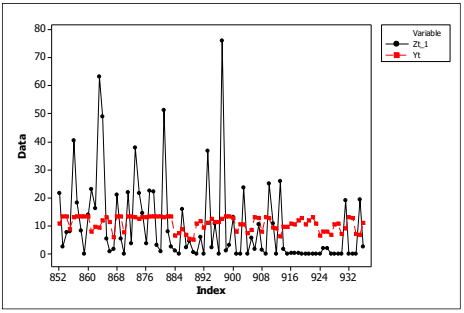

Gambar 4.10 Data *Testing* (Aktual) dengan Nilai Ramalan Model RBFNN

Gambar 4.10 menujukkan bahwa hasil nilai ramalan mendekati nilai data aktual terlihat dari plot *time series* yang dihasilkan.

4.5 Perbandingan Model ARIMA dan RBFNN

Untuk membandingkan nilai ramalan model ARIMA dan RBFNN yang telah didapatkan, akan digunakan MSE sebagai kriteria kebaikan model. Nilai MSE model ARIMA dan RBFNN dapat dilihat pada Tabel 4.8

Tabel 4.8 Perbandingan Kebaikan Model ARIMA dan RBFNN

Model	MSE
ARIMA ([1,9,12,35,55,58],1,1)	16.902
RBFNN	**5.270**

Tabel 4.8 menunjukkan bahwa model ARIMA memiliki nilai MSE sebesar 16,902 sedangkan model RBFNN memiliki nilai MSE sebesar 5,270. Berdasarkan hasil tersebut diketahui Model RBFNN memiliki nilai MSE lebih kecil daripada model ARIMA, sehingga dapat disimpulkan bahwa model RBFNN lebih baik untuk meramalkan curah hujan di Stasiun Juanda.

4.6 Peramalan Curah Hujan di Stasiun Juanda

Model terbaik yang digunakan untuk peramalan curah hujan di Stasiun Juanda adalah model RBFNN. Berdasarkan model RBFNN yang terbentuk maka hasil ramalan curah hujan di Stasiun Juanda untuk periode 852 adalah sebagai berikut

$$\hat{Z}_{852} = 13.435 - 1.497 h_1(x) - 10.746 h_2(x) - 12.352 h_3(x)$$

$$\hat{Z}_{852} = 13.435 - 1.497(0) - 10.746(0) - 12.352(0.219)$$

$$\hat{Z}_{852} = 10.732$$

dengan perhitungan nilai $h_j(x)$ sebagai berikut

$$h_j(x) = \exp\left\{\left[\left(\frac{(x_i - c_{1j})^2}{2\sigma_1^2}\right) + \left(\frac{(x_i - c_{2j})^2}{2\sigma_1^2}\right) + \ldots + \left(\frac{(x_i - c_{12j})^2}{2\sigma_1^2}\right)\right]\right.$$

$$h_1(x) = \exp\left\{-\left[\left(\frac{(3{,}6 - 0{,}032)^2}{2(0{,}337)^2}\right) + \left(\frac{9{,}6 - 0{,}055)^2}{2(0{,}0.337)^2}\right) + \ldots + \left(\frac{(1.4 - 0{,}060)^2}{2(0{,}337)^2}\right)\right]\right.$$

$$h_1(x) = 0$$

$$h_2(x) = \exp\left\{-\left[\left(\frac{(3{,}6 - 3.924)^2}{2(8.560)^2}\right) + \left(\frac{9{,}6 - 3.759)^2}{2(8.560)^2}\right) + \ldots + \left(\frac{(1.4 - 0.820)^2}{2(8.560)^2}\right)\right]\right.$$

$$h_2(x) = 0$$

$$h_3(x) = \exp\left\{-\left[\left(\frac{(3{,}6 - 10.903)^2}{2(28.583)^2}\right) + \left(\frac{9{,}6 - 10.948)^2}{2(28.583)^2}\right) + \ldots + \left(\frac{(1.4 - 11.205)^2}{2(28.583)^2}\right)\right]\right.$$

$$h_3(x) = 0.219$$

Berdasarkan perhitungan diatas, didapatkan nilai ramalan curah hujan di Stasiun Juanda periode 852 sebesar 10.732 mm. Perhitungan nilai ramalan periode 853 sampai 865 akan dilakukan dengan cara yang sama. Hasil peramalan dapat dilihat pada Tabel 4.9

Tabel 4.9 Ramalan Curah Hujan di Stasiun Juanda Periode 852-865

Periode	**Nilai Ramalan**
852	10.732
853	13.265
854	13.330
855	8.809
856	13.193
857	13.431
858	13.303
859	13.388
860	13.403
861	7.981
862	9.611
863	9.523
864	11.950
865	13.041

Hasil ramalan curah hujan di Stasiun Juanda menggunakan model RBFNN dapat divisualisasikan pada Gambar 4.11

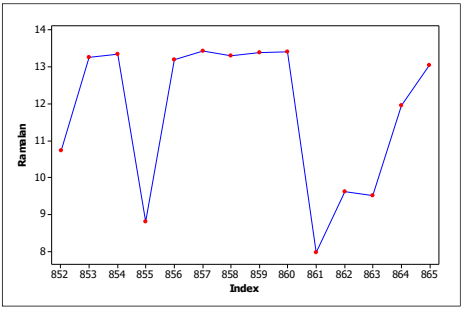

Gambar 4.11 *Time Series Plot* Nilai Ramalan Model RBFNN

Gambar 4.11 menjelasakan nilai ramalan yang dihasilkan model RBFNN periode 852 hingga 865, pola data bergerak fluktuatif. Curah hujan tertinggi berada pada periode ke-857 sebesar 13.841 mm dan curah hujan terendah berada pada periode ke-861 sebesar 7.981 mm.

BAB V
KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan peramalan curah hujan di Stasiun Juanda dapat ditarik kesimpulan sebagai berikut.

1. Model ARIMA terbaik untuk meramalkan curah hujan di Stasiun Juanda adalah ARIMA ([1,9,12,35,55,58],1,1).
2. Model *Radial Basis Function* (RBFNN) yang optimum adalah model dengan 12 *neuron* pada input, 3 *neuron* pada lapisan tersembunyi, dan 1 *neuron* pada lapisan output.
3. Berdasarkan perbandingan kebaikan model dengan nilai MSE pada model ARIMA dan RBFNN, dapat disimpulkan bahwa model RBFNN lebih baik dalam meramalkan curah hujan di Stasiun Juanda karena memiliki nilai MSE lebih kecil dibandingkan model ARIMA.
4. Peramalan curah hujan periode 852 hingga 865 memiliki pola data yang bergerak fluktuatif. Curah hujan tertinggi berada pada periode ke-857 sebesar 13.841 mm dan curah hujan terendah berada pada periode ke-861 sebesar 7.981 mm.

5.2 Saran

Saran yang dapat diberikan berdasarkan hasil analisis dan pembahasan peramalan curah hujan di Stasiun Juanda adalah untuk penelitian selanjutnya sebaiknya menggunakan deteksi outlier untuk mengatasi residual model ARIMA yang tidak berdistribusi normal, sehingga hasil ramalan yang diperoleh dapat menghasilkan error yang lebih kecil.

DAFTAR PUSTAKA

[BMKG] Badan Meteorologi, Klimatologi dan Geofisika. Diakses dari *website www.dataonline.bmkg.go.id* pada 1 Mei 2021.

Bowerman, B., & O'Connell. 1993. *Forecasting and Time Series: An Applied Approach, 3rd ed.* California: Duxbury Press.

Cryer, J. D. & Kung-shik Chan. 2008. *Time Series Analysis with Application in R.* New York : Springer.

Fausett, L. 1994. *Fundamentals of Neural Networks (Architectures, Algorithms, and Applications).* Upper Saddle River, New Jersey: Prentice.

Insani, N. H. 2015. *Peramalan Curah Hujan Dengan Menggunakan Metode Arima Box-Jenkins Sebagai Pendukung Kalender Tanam Padi di Kabupaten Bojonegoro.* Tugas Akhir. Surabaya: Institut Teknologi Sepuluh Nopember (ITS)

Kristianda, F. & Fithriasari, K. 2016. *Peramalan Curah Hujan di Wilayah Surabaya Timur dengan Vector Autoregressive Neural Network.* Jurnal Sains dan Seni ITS Vol.5 No.2 (2337-3520)

Makridakis, S., Wheelwright, S. C., & McGee, V. E. 1999. *Metode Dan Aplikasi Peramalan.* (U. S. Andriyanto, & A. Basith, Trans.). Jakarta : Erlangga.

Maswir, B. I. 2013. Retrieved from *Penerbangan Bagi Indo dan Ilmu Seputar Dunia Penerbangan:* http://boniepku. blogspot.co.id/2013/10/cuaca-penerbangan-3.html

Purba, Novelia. 2016. *Pemodelan Curah Hujan di Kabupaten Banyuwangi Dengan Metode ARIMA dan Radial Basis Function Neural Network.* Tugas Akhir. Surabaya: Institut Teknologi Sepuluh Nopember (ITS).

Rencher, A. 2002. *Methods of Multivariate Analysis.* Amerika: A John Willey & Sons, Inc.

Soerjadi. 2010. Retrieved from *Manfaat dan Bahaya Cuaca dalam Penerbangan:* http:// pustakacuaca.blogspot.co.id/ 2010/08/manfaat-dan-bahaya-cuaca-dalam.html

Suara Surabaya. 2020. Retrieved from https://www.suarasurabaya.net/kelanakota/2020/bmkg-musim-hujan-di-jatim-diprakirakan-awal-november/

Swarinoto, Y.S, & Sugiyono. (2011). *Pemanfaatan Suhu Udara dan Kelembapan Udara dalam Persamaan Regresi untuk Simulasi Prediksi Total Hujan Bulanan di Bandar Lampung*. BMKG, Bandar Lampung.

Wei, W.W.S., (2006). *Time Analysis Univariate and Multivariate Methods. (Second Edition)*. USA: Pearson Education, Inc.

Zhang, G.P. (2004). *Neural Network in Business Forcasting.* USA: Idea Group, Inc.

LAMPIRAN

Lampiran 1. Data Curah Hujan di Stasiun Juanda

Periode	Curah Hujan (mm)
1	0
2	0
3	6.8
4	38.5
5	1
6	0
7	0
8	6.4
9	3.9
10	0
11	0.5
12	2
13	0
14	8.2
15	11.5
16	30.2
17	51.2
18	38
19	17.6
20	30.5
21	129
22	19.6
:	:
850	19.3
851	2.6

Lampiran 2. Perhitungan Data Hilang

Bulan	Tahun	Tanggal	Tahun				Rata-Rata (mm)
			2015	2016	2017	2018	
Januari	2021	4	0	11.1	0	64.3	18.9
	2019	9	0	0	0	15.9	4.0
	2021	13	8	0	54.5	0	15.6
	2020	14	16.1	8.4	0.4	2.7	6.9
	2020	24	60.9	17.1	6.2	7	22.8
	2020	27	0	16.5	6	1.2	5.9
Februari	2020	5	63.7	54	0	20	34.4
	2021	10	19	26.4	0	27.6	18.3
	2021	19	0.7	2.5	0	0	0.8
	2019	21	7.2	15.3	0.4	0	5.7
	2019	27	0	31.9	0.8	27.7	15.1
Maret	2021	1	1.1	0	11.2	2.5	3.7
	2019	5	56.4	0	0	12.2	17.2
	2020	9	17.4	0	0	58.4	19.0
	2019	11	25.8	19.8	0	18	15.9
	2020	12	0	9.8	0	3	3.2
	2020	16	45.6	0	0	0	11.4
	2021	18	59	0	10.5	78	36.9
	2020	25	0.2	0.6	0	4	1.2
April	2020	2	0	56.5	0	88.5	36.3
	2020	4	0.2	16	2.4	0	4.7
	2019	5	8.5	19.5	1	0	7.3
	2019	8	37.6	2.1	0	0.2	10.0
	2020	9	0	46.5	34.3	1.3	20.5
	2019	17	0	0	0	0	0.0
	2021	19	7.1	0	0.7	0	2.0
	2020	27	0	0	0	0.2	0.1
	2020	28	5.4	0	0	0	1.4
:	:	:	:	:	:	:	:
Desember	2019	10	0	0.6	1.4	0	0.5
	2019	14	0	5.3	3.8	1	2.5
	2019	15	10	0	4.7	0	3.7
	2019	22	7.5	0	37.5	30.2	18.8
	2020	23	0.5	0	3.7	0.7	1.2
	2019	27	0.3	29	4.5	1	8.7
	2019	30	2.6	7.2	0	0	2.5

Lampiran 3. Dugaan Model ARIMA

No	Model ARIMA
1	ARIMA (6,1,0)
2	ARIMA ([9,10,11,28,34,56], 1,0)
3	ARIMA ([9,11,28,34,56],1,0)
4	ARIMA ([9,11,28,34],1,0)
5	ARIMA ([9,11, 34],1,0)
6	ARIMA ([9,34],1,0)
7	ARIMA (0,1,[1,12,35,55])
8	ARIMA (0,1,[1,35,55])
9	ARIMA (0,1,[1,55])
10	ARIMA (0,1,1)
11	ARIMA (6,1,[1,12,35,55])
12	ARIMA (6,1,[12,35,55])
13	ARIMA (6,1,[12,55])
14	ARIMA (6,1,[12])
15	ARIMA ([9,10,11,28,34,56],1,[1,12,35,55])
16	ARIMA ([9,10,28,34,56],1,[1,12,35,55])
17	ARIMA ([9,10,28,34],1,[1,12,35,55])
18	ARIMA ([9,10,34],1,[1,12,35,55])
19	ARIMA ([9,10,34],1,[1,35,55])
20	ARIMA ([9,34],1,[1,35,55])
21	ARIMA ([9],1,[1,35,55])
22	ARIMA ([9],1,[1,55])
23	ARIMA ([9],1,1)
24	ARIMA (6,1,[35])
25	ARIMA (6,1,[55])
26	ARIMA ([9],1,[12])
27	ARIMA ([9],1,[35])
28	ARIMA ([9],1,[55])
29	ARIMA ([10],1,[12])
30	ARIMA ([10],1,[35])
31	ARIMA ([1,12,35,58],1,[1,50])
32	ARIMA ([1,9,12,35,55,58],1,1)
33	ARIMA (1,1,1)

Lampiran 4. *Syntax* Estimasi Parameter

```
data order;
input y;
datalines;
1.00000
1.00000
0.12821
:
0.02717
0.10101
0.03597
;
proc arima data=order;
identify var=y(1);
estimate
p=() q=()
noint
method=CLS
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=120;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 5. Estimasi Parameter Model ARIMA

No	Model	Estimasi Parameter	Nilai Koefisien	SE	Thitung	Pvalue
1	ARIMA (6,1,0)	AR1,1	-0.676	0.037	-18.260	<0.0001
		AR1,2	-0.494	0.044	-11.220	<0.0001
		AR1,3	-0.388	0.046	-8.390	<0.0001
		AR1,4	-0.319	0.046	-6.890	<0.0001
		AR1,5	-0.211	0.044	-4.780	<0.0001
		AR1,6	-0.087	0.037	-2.350	0.019

Lampiran 5. Estimasi Parameter Model ARIMA (Lanjutan)

No	Model	Estimasi Parameter	Nilai Koefisien	SE	Thitung	Pvalue
2	ARIMA ([9,10,11,28,34,56],1,0)	AR1,1	-0.080	0.043	-1.860	0.063
		AR1,2	0.016	0.048	0.350	0.729
		AR1,3	-0.046	0.043	-1.060	0.288
		AR1,4	0.051	0.038	1.350	0.178
		AR1,5	-0.077	0.038	-2.020	0.044
		AR1,6	0.034	0.039	0.870	0.385
3	ARIMA ([9,11,28,34,56],1,0)	AR1,1	-0.087	0.037	-2.340	0.020
		AR1,2	-0.053	0.037	-1.420	0.157
		AR1,3	0.051	0.038	1.350	0.178
		AR1,4	-0.076	0.038	-2.010	0.045
		AR1,5	0.034	0.039	0.870	0.382
4	ARIMA ([9,11,28,34],1,0)	AR1,1	-0.085	0.037	-2.290	0.023
		AR1,2	-0.054	0.037	-1.430	0.152
		AR1,3	0.052	0.038	1.390	0.166
		AR1,4	-0.079	0.038	-2.090	0.037
5	ARIMA ([9,11,34],1,0)	AR1,1	-0.087	0.037	-2.350	0.019
		AR1,2	-0.052	0.037	-1.390	0.165
		AR1,3	-0.077	0.038	-2.040	0.041
6	ARIMA ([9,34],1,0)	AR1,1	-0.086	0.037	-2.320	0.0206
		AR1,2	-0.078	0.037	-2.080	0.0379
7	ARIMA (0,1,[1,12,35,55])	MA1,1	0.837	0.020	41.760	<.0001
		MA1,2	-0.018	0.019	-0.930	0.3502
		MA1,3	-0.031	0.020	-1.530	0.1264
		MA1,4	-0.030	0.020	-1.430	0.1524
8	ARIMA (0,1,[1,35,55])	MA1,1	0.838	0.020	41.880	<.0001
		MA1,2	-0.029	0.020	-1.430	0.153
		MA1,3	-0.034	0.020	-1.650	0.0994
9	ARIMA (0,1,[1,55])	MA1,1	0.841	0.019	42.310	<.0001
		MA1,2	-0.034	0.021	-1.610	0.1076
10	ARIMA (0,1,1)	MA1,1	0.833	0.020	40.690	<.0001

Lampiran 5. Estimasi Parameter Model ARIMA (Lanjutan)

No	Model	Estimasi Parameter	Nilai Koefisien	SE	Thitung	Pvalue
11	ARIMA (6,1,[1,12,35, 55])	MA1,1	0.061	0.229	0.270	0.790
		MA1,2	-0.081	0.038	-2.150	0.032
		MA1,3	-0.082	0.038	-2.140	0.032
		MA1,4	0.089	0.039	2.280	0.023
		AR1,1	-0.606	0.231	-2.630	0.009
		AR1,2	-0.444	0.157	-2.840	0.005
		AR1,3	-0.337	0.115	-2.930	0.004
		AR1,4	-0.281	0.091	-3.090	0.002
		AR1,5	-0.191	0.074	-2.570	0.010
		AR1,6	-0.076	0.051	-1.470	0.141
12	ARIMA (6,1,[12,35,5 5])	MA1,1	-0.082	0.038	-2.170	0.030
		MA1,2	-0.081	0.038	-2.120	0.035
		MA1,3	0.092	0.039	2.350	0.019
		AR1,1	-0.666	0.037	-17.93	<.0001
		AR1,2	-0.484	0.044	-10.98	<.0001
		AR1,3	-0.364	0.046	-7.860	<.0001
		AR1,4	-0.301	0.046	-6.480	<.0001
		AR1,5	-0.205	0.044	-4.630	<.0001
		AR1,6	-0.082	0.037	-2.180	0.030
13	ARIMA (6,1,[12,55])	MA1,1	-0.088	0.038	-2.350	0.019
		MA1,2	0.087	0.039	2.230	0.026
		AR1,1	-0.668	0.037	-18.02	<.0001
		AR1,2	-0.488	0.044	-11.10	<.0001
		AR1,3	-0.370	0.046	-8.010	<.0001
		AR1,4	-0.305	0.046	-6.590	<.0001
		AR1,5	-0.210	0.044	-4.740	<.0001
		AR1,6	-0.088	0.037	-2.370	0.018
14	ARIMA (6,1,[12])	MA1,1	-0.096	0.038	-2.540	0.012
		AR1,1	-0.673	0.037	-18.16	<.0001
		AR1,2	-0.495	0.044	-11.23	<.0001
		AR1,3	-0.381	0.046	-8.220	<.0001
		AR1,4	-0.309	0.046	-6.660	<.0001
		AR1,5	-0.206	0.044	-4.660	<.0001
		AR1,6	-0.087	0.037	-2.350	0.019

Lampiran 5. Estimasi Parameter Model ARIMA (Lanjutan)

No	Model	Estimasi Parameter	Nilai Koefisien	SE	Thitung	Pvalue
15	ARIMA ([9,10,11,28, 34,56],1,[1,1 2,35,55])	MA1,1	0.830	0.021	40.060	<.0001
		MA1,2	-0.016	0.021	-0.790	0.431
		MA1,3	-0.035	0.021	-1.630	0.103
		MA1,4	-0.028	0.025	-1.120	0.264
		AR1,1	-0.106	0.038	-2.790	0.005
		AR1,2	0.028	0.038	0.740	0.462
		AR1,3	0.003	0.038	0.070	0.941
		AR1,4	0.025	0.038	0.670	0.504
		AR1,5	-0.046	0.038	-1.220	0.222
		AR1,6	0.008	0.045	0.170	0.862
16	ARIMA ([9,10,28,34, 56],1,[1,12, 35,55])	MA1,1	0.830	0.021	40.110	<.0001
		MA1,2	-0.016	0.021	-0.790	0.430
		MA1,3	-0.035	0.021	-1.640	0.102
		MA1,4	-0.028	0.025	-1.120	0.265
		AR1,1	-0.106	0.038	-2.790	0.005
		AR1,2	0.028	0.038	0.750	0.454
		AR1,3	0.025	0.038	0.670	0.503
		AR1,4	-0.046	0.038	-1.220	0.222
		AR1,5	0.008	0.045	0.180	0.861
17	ARIMA ([9,10,28,34], 1,[1,12,35, 55])	MA1,1	0.831	0.021	40.250	<.0001
		MA1,2	-0.016	0.021	-0.780	0.438
		MA1,3	-0.035	0.021	-1.640	0.102
		MA1,4	-0.030	0.022	-1.400	0.161
		AR1,1	-0.105	0.038	-2.790	0.005
		AR1,2	0.028	0.038	0.760	0.450
		AR1,3	0.026	0.038	0.680	0.500
		AR1,4	-0.047	0.038	-1.230	0.218
18	ARIMA ([9,10,34],1, [1,12,35,55])	MA1,1	0.832	0.021	40.450	<.0001
		MA1,2	-0.015	0.021	-0.750	0.455
		MA1,3	-0.033	0.021	-1.570	0.117
		MA1,4	-0.030	0.022	-1.410	0.159
		AR1,1	-0.105	0.038	-2.790	0.005
		AR1,2	0.028	0.038	0.760	0.449
		AR1,3	-0.047	0.038	-1.240	0.216

Lampiran 5. Estimasi Parameter Model ARIMA (Lanjutan)

No	Model	Estimasi Parameter	Nilai Koefisien	SE	Thitung	Pvalue
19	ARIMA ([9,10,34],1,[1,35,55])	MA1,1	0.832	0.020	40.640	<.0001
		MA1,2	-0.031	0.021	-1.490	0.136
		MA1,3	-0.034	0.021	-1.580	0.115
		AR1,1	-0.107	0.037	-2.860	0.004
		AR1,2	0.026	0.037	0.700	0.485
		AR1,3	-0.047	0.038	-1.230	0.218
20	ARIMA ([9,34],1,[1,35,55])	MA1,1	0.831	0.021	40.520	<.0001
		MA1,2	-0.031	0.021	-1.480	0.139
		MA1,3	-0.034	0.022	-1.560	0.120
		AR1,1	-0.104	0.037	-2.810	0.005
		AR1,2	-0.046	0.038	-1.210	0.225
21	ARIMA ([9],1,[1,35,55])	MA1,1	0.830	0.021	40.400	<.0001
		MA1,2	-0.031	0.021	-1.450	0.147
		MA1,3	-0.033	0.021	-1.520	0.129
		AR1,1	-0.104	0.037	-2.800	0.005
22	ARIMA ([9],1,[1,55])	MA1,1	0.834	0.020	40.910	<.0001
		MA1,2	-0.032	0.022	-1.480	0.139
		AR1,1	-0.104	0.037	-2.790	0.005
23	ARIMA ([9],1,1)	MA1,1	0.827	0.021	39.720	<.0001
		AR1,1	-0.107	0.037	-2.870	0.004
24	ARIMA (6,1,[35])	MA1,1	-0.082	0.038	-2.150	0.032
		AR1,1	-0.674	0.037	-18.16	<.0001
		AR1,2	-0.490	0.044	-11.09	<.0001
		AR1,3	-0.382	0.046	-8.250	<.0001
		AR1,4	-0.313	0.046	-6.750	<.0001
		AR1,5	-0.206	0.044	-4.670	<.0001
		AR1,6	-0.080	0.037	-2.150	0.032
25	ARIMA (6,1,[55])	MA1,1	0.093	0.039	2.390	0.017
		AR1,1	-0.671	0.037	-18.09	<.0001
		AR1,2	-0.486	0.044	-11.07	<.0001
		AR1,3	-0.374	0.046	-8.110	<.0001
		AR1,4	-0.315	0.046	-6.810	<.0001
		AR1,5	-0.215	0.044	-4.870	<.0001
		AR1,6	-0.088	0.037	-2.370	0.018

Lampiran 5. Estimasi Parameter Model ARIMA (Lanjutan)

No	Model	Estimasi Parameter	Nilai Koefisien	SE	Thitung	Pvalue
26	ARIMA ([9],1,[12])	MA1,1	-0.119	0.037	-3.190	0.002
		AR1,1	-0.090	0.037	-2.420	0.016
27	ARIMA ([9],1,[35])	MA1,1	-0.093	0.038	-2.460	0.014
		AR1,1	-0.085	0.037	-2.280	0.023
28	ARIMA ([9],1,[55])	MA1,1	0.117	0.039	3.020	0.003
		AR1,1	-0.082	0.037	-2.210	0.027
29	ARIMA ([10],1,[12])	MA1,1	-0.124	0.037	-3.320	0.001
		AR1,1	0.083	0.037	2.220	0.027
30	ARIMA ([10],1,[35])	MA1,1	-0.097	0.038	-2.560	0.011
		AR1,1	0.075	0.037	2.000	0.046
31	ARIMA ([1,12,35,58],1,[1,50])	MA1,1	0.883	0.020	44.000	<.0001
		MA1,2	0.058	0.018	3.230	0.001
		AR1,1	0.146	0.043	3.410	0.001
		AR1,2	0.083	0.037	2.240	0.025
		AR1,3	0.073	0.037	1.970	0.049
		AR1,4	0.140	0.039	3.590	0.000
32	ARIMA ([1,9,12,35,55,58],1,1)	MA1,1	0.878	0.022	40.270	<.0001
		AR1,1	0.146	0.043	3.370	0.001
		AR1,2	-0.074	0.037	-1.990	0.047
		AR1,3	0.084	0.037	2.290	0.023
		AR1,4	0.082	0.037	2.220	0.027
		AR1,5	-0.081	0.038	-2.130	0.033
		AR1,6	0.122	0.038	3.180	0.002
33	ARIMA (1,1,1)	MA1,1	0.886	0.020	43.800	<.0001
		AR1,1	0.165	0.043	3.820	0.000

Lampiran 6. Cek Diagnostik Residual *White Noise*

1) ARIMA (6,1,0)

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	.	0	.
12	37.09	6	<.0001
18	39.41	12	<.0001
24	47.52	18	0.0002
30	54.58	24	0.0004
36	64.8	30	0.0002
42	71.3	36	0.0004
48	76.53	42	0.0009

2) ARIMA ([9,34],1,0)

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	142.42	4	<.0001
12	155.39	10	<.0001
18	161.52	16	<.0001
24	169.29	22	<.0001
30	176.93	28	<.0001
36	185.05	34	<.0001
42	193.42	40	<.0001
48	197.24	46	<.0001

3) ARIMA (0,1,1)

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	15.19	5	0.0096
12	34.51	11	0.0003
18	36.99	17	0.0034
24	45.56	23	0.0034
30	50.89	29	0.0072
36	60.58	35	0.0046
42	68.86	41	0.0041
48	73.75	47	0.0076

4) ARIMA (6,1,[12])

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	.	0	.
12	27.64	5	<.0001
18	30.18	11	0.0015
24	39.73	17	0.0014
30	47.98	23	0.0017
36	58.37	29	0.001
42	65.42	35	0.0014
48	69.8	41	0.0033

Lampiran 6. Cek Diagnostik Residual *White Noise* (Lanjutan)

5) ARIMA ([9],1,1)

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	15.45	4	0.0038
12	26.91	10	0.0027
18	30.07	16	0.0176
24	38.42	22	0.0164
30	43.43	28	0.0316
36	52.91	34	0.0204
42	59.72	40	0.0231
48	64.56	46	0.0367

6) ARIMA (6,1,[35])

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	.	0	.
12	37.23	5	<.0001
18	39.17	11	<.0001
24	46.84	17	0.0001
30	53.9	23	0.0003
36	59.38	29	0.0007
42	66.55	35	0.001
48	71.33	41	0.0023

7) ARIMA (6,1,[55])

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	.	0	.
12	37.63	5	<.0001
18	39.84	11	<.0001
24	48.05	17	<.0001
30	55.39	23	0.0002
36	66.09	29	0.0001
42	72.26	35	0.0002
48	77.64	41	0.0005

8) ARIMA ([9],1,[12])

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	141.84	4	<.0001
12	143.83	10	<.0001
18	147.21	16	<.0001
24	157.1	22	<.0001
30	165.13	28	<.0001
36	180.52	34	<.0001
42	189.32	40	<.0001
48	193.2	46	<.0001

Lampiran 6. Cek Diagnostik Residual *White Noise* (Lanjutan)

9)ARIMA ([9],1,[35])

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	145.05	4	<.0001
12	158.52	10	<.0001
18	164.25	16	<.0001
24	172.91	22	<.0001
30	181.14	28	<.0001
36	188.17	34	<.0001
42	196.18	40	<.0001
48	199.08	46	<.0001

10) ARIMA ([9],1,[55])

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	144.46	4	<.0001
12	157.58	10	<.0001
18	165.21	16	<.0001
24	173.91	22	<.0001
30	180.84	28	<.0001
36	197.7	34	<.0001
42	205.55	40	<.0001
48	209.64	46	<.0001

11) ARIMA ([10],1,[12])

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	141.19	4	<.0001
12	143.68	10	<.0001
18	146.53	16	<.0001
24	155.99	22	<.0001
30	163.95	28	<.0001
36	179.49	34	<.0001
42	187.98	40	<.0001
48	191.4	46	<.0001

12) ARIMA ([10],1,[35])

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	141.87	4	<.0001
12	154.55	10	<.0001
18	159.19	16	<.0001
24	167.86	22	<.0001
30	175.82	28	<.0001
36	182.59	34	<.0001
42	190.21	40	<.0001
48	192.82	46	<.0001

Lampiran 6. Cek Diagnostik Residual *White Noise* (Lanjutan)

13) ARIMA ([1,12,35,58],1,[1,50])

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	.	0	.
12	9.66	6	0.1395
18	13.23	12	0.3528
24	22.86	18	0.1959
30	28.73	24	0.2306
36	34.43	30	0.2638
42	41.13	36	0.2559
48	43.23	42	0.4187

14) ARIMA ([1,9,12,35,55,58],1,1)

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	.	0	.
12	6.55	5	0.2559
18	9.68	11	0.5591
24	19.85	17	0.2819
30	25.74	23	0.3135
36	30.72	29	0.3785
42	37.03	35	0.3756
48	40.38	41	0.4979

15) ARIMA (1,1,1)

Autocorrelation Check of Residuals			
To Lag	Chi-Square	DF	Pr > ChiSq
6	2.68	4	0.6134
12	17.39	10	0.0662
18	19.7	16	0.2339
24	28.58	22	0.1572
30	33.77	28	0.2086
36	43.78	34	0.1215
42	50.92	40	0.1156
48	54.73	46	0.1769

Lampiran 7. Cek Diagnostik Residual Berdistribusi Normal

1) ARIMA ([1,12,35,58],1,[1,50])

Tests for Normality				
Test	Statistic		p Value	
Shapiro-Wilk	W	0.978035	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.117924	Pr > D	<0.0100
Cramer-von Mises	W-Sq	1.742755	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	7.97801	Pr > A-Sq	<0.0050

Lampiran 7. Cek Diagnostik Residual Berdistribusi Normal (Lanjutan)

2) ARIMA ([1,9,12,35,55,58],1,1)

Tests for Normality				
Test	Statistic		p Value	
Shapiro-Wilk	W	0.973147	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.125679	Pr > D	<0.0100
Cramer-von Mises	W-Sq	2.079096	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	9.669777	Pr > A-Sq	<0.0050

3) ARIMA (1,1,1)

Tests for Normality				
Test	Statistic		p Value	
Shapiro-Wilk	W	0.973424	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.16327	Pr > D	<0.0100
Cramer-von Mises	W-Sq	2.206306	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	9.903512	Pr > A-Sq	<0.0050

Lampiran 8. Perhitungan Manual Pemilihan Model Terbaik ARIMA

Periode	Z_t	Y_1	Y_2	Y_3	$(Z_t-Y_1)^2$	$(Z-Y_2)^2$	$(Z_t-Y_3)^2$
732	9.1	4.040	6.219	5.336	25.600	8.301	14.166
733	7	2.822	3.995	4.708	39.407	26.059	19.289
734	34	3.754	3.283	4.617	28.582	33.838	20.099
735	18.9	3.720	4.337	4.604	28.942	22.691	20.214
736	15.1	2.728	2.659	4.600	40.605	41.488	20.252
737	84.8	7.570	4.037	4.600	2.341	25.633	20.252
738	14.5	4.386	3.687	4.600	22.222	29.297	20.252
739	89.8	5.283	4.558	4.600	14.572	20.631	20.252
740	0	7.524	7.082	4.600	2.482	4.072	20.252
741	13	4.205	5.219	4.600	23.959	15.061	20.252
742	2.5	3.521	4.912	4.600	31.124	17.543	20.252
743	2.3	3.537	4.466	4.600	30.943	21.471	20.252
744	15.6	3.358	4.583	4.600	32.971	20.404	20.252
745	9.3	2.978	3.467	4.600	37.479	31.726	20.252
746	0	2.739	3.255	4.600	40.463	34.162	20.252
747	1.2	2.598	3.501	4.600	42.275	31.344	20.252
748	8.5	3.857	8.071	4.600	27.494	1.059	20.252
749	12.4	3.619	5.708	4.600	30.039	11.507	20.252
:	:	:	:	:	:	:	:
851	2.6	2.430	5.269	4.600	44.487	14.679	20.252
				Jumlah	**4779.288**	**2028.246**	**2422.960**
				MSE	**39.827**	**16.902**	**20.191**

Lampiran 9. Persamaan Model ARIMA ([1,9,12,35,55,58],1,1)

$$(1-B)(1-\phi_1 B-\phi_9 B^9-\phi_{12}B^{12}-\phi_{35}B^{35}-\phi_{55}B^{55}-\phi_{58}B^{58})Z_t=(1-\theta_1 B)a_t$$

$$(1-\phi_1 B-\phi_9 B^9-\phi_{12}B^{12}-\phi_{35}B^{35}-\phi_{55}B^{55}-\phi_{58}B^{58}-B+\phi_1 B^2$$

$$+\phi_9 B^{10}+\phi_{35}B^{36}+\phi_{55}B^{56}+\phi_{58}B^{59})Z_t=a_t-\theta_1 a_{t-1}$$

$$Z_t-\phi_1 Z_{t-1}-\phi_9 Z_{t-9}-\phi_{12}Z_{t-12}-\phi_{35}Z_{t-35}-\phi_{55}Z_{t-55}-\phi_{58}Z_{t-58}$$

$$-Z_{t-1}+\phi_1 Z_{t-2}+\phi_9 Z_{t-10}+\phi_{12}Z_{t-13}+\phi_{35}Z_{t-36}+\phi_{55}Z_{t-56}$$

$$+\phi_{58}Z_{t-59}=a_t-\theta_1 a_{t-1}$$

$$Z_t=(1+\phi_1)Z_{t-1}-\phi_1 Z_{t-2}+\phi_9 Z_{t-9}-\phi_9 Z_{t-10}+\phi_{12}Z_{t-12}-\phi_{12}Z_{t-13}$$

$$+\phi_{35}Z_{t-35}-\phi_{35}Z_{t-36}+\phi_{55}Z_{t-55}-\phi_{55}Z_{t-56}+\phi_{58}Z_{t-58}$$

$$-\phi_{58}Z_{t-59}+a_t-\theta_1 a_{t-1}$$

$$Z_t=1{,}146Z_{t-1}-0{,}146Z_{t-2}-0{,}074Z_{t-9}+0{,}074Z_{t-10}+0{,}084Z_{t-12}-0{,}084Z_{t-13}$$

$$+0{,}082Z_{t-35}-0{,}082Z_{t-36}-0{,}081Z_{t-55}+0{,}081Z_{t-56}+0{,}122Z_{t-58}-0{,}122Z_{t-59}$$

$$+a_t-0{,}878a_{t-1}$$

Lampiran 10. *Syntax* dan Hasil Uji Terasvirta

```
library(readxl)
data <- read_excel("E:/SEMESTER 8/PROJECT
AKHIR/URGENT/Project Akhir/Data Curah Hujan.xlsx")
View(data)
library("tseries")
Y <- as.ts(data)
terasvirta.test(Y,1,c("F"))

Teraesvirta Neural Network Test
data:  Y
F = 20.212, df1 = 2, df2 = 848, p-value = 2.659e-09
```

Lampiran 11. *Output Software* RBFNN

1) 2 Node

Model Summary

Training	Sum of Squares Error	77097.531
	Relative Error	.902
	Training Time	0:00:00.00
Testing	Sum of Squares Error	9183.693
	Relative Error	.962

Dependent Variable: Zt

Parameter Estimates

		Predicted		
		Hidden Layer[a]		Output Layer
Predictor		H(1)	H(2)	Zt
Input Layer	Zt1	.032	9.475	
	Zt2	.055	9.477	
	Zt9	.028	9.315	
	Zt10	.013	9.259	
	Zt12	.020	9.107	
	Zt13	.029	9.042	
	Zt35	.034	9.204	
	Zt36	.038	9.158	
	Zt55	.059	9.041	
	Zt56	.022	9.117	
	Zt58	.042	9.089	
	Zt59	.060	9.079	
Hidden Unit Width		.337	26.373	
Hidden Layer	(Intercept)			13.708
	H(1)			-5.342
	H(2)			-17.895

a. Displays the center vector for each hidden unit.

2) 3 Node

Model Summary

Training	Sum of Squares Error	76574.144
	Relative Error	.896
	Training Time	0:00:00.00
Testing	Sum of Squares Error	9242.809
	Relative Error	.969

Dependent Variable: Zt

Lampiran 11. *Output Software* RBFNN (Lanjutan)

Parameter Estimates

Predictor		Predicted			
		Hidden Layer[a]			Output Layer
		H(1)	H(2)	H(3)	Zt
Input Layer	Zt1	.032	3.924	10.903	
	Zt2	.055	3.759	10.948	
	Zt9	.028	3.780	10.739	
	Zt10	.013	4.152	10.574	
	Zt12	.020	1.106	11.166	
	Zt13	.029	.445	11.255	
	Zt35	.034	.495	11.446	
	Zt36	.038	.997	11.258	
	Zt55	.059	.549	11.227	
	Zt56	.022	1.380	11.108	
	Zt58	.042	1.401	11.067	
	Zt59	.060	.820	11.205	
Hidden Unit Width		.337	8.560	28.583	
Hidden Layer	(Intercept)				13.435
	H(1)				-1.597
	H(2)				-10.746
	H(3)				-12.352

a. Displays the center vector for each hidden unit.

3) 4 Node

Model Summary

Training	Sum of Squares Error	74650.443
	Relative Error	.873
	Training Time	0:00:00.00
Testing	Sum of Squares Error	9430.085
	Relative Error	.988

Dependent Variable: Zt

Lampiran 11. *Output Software* RBFNN (Lanjutan)

Parameter Estimates

Predictor		Predicted				
		Hidden Layer[a]				Output Layer
		H(1)	H(2)	H(3)	H(4)	Zt
Input Layer	Zt1	.032	3.924	.217	13.078	
	Zt2	.055	3.759	.470	13.081	
	Zt9	.028	3.780	.945	12.732	
	Zt10	.013	4.152	.532	12.618	
	Zt12	.020	1.106	1.404	13.153	
	Zt13	.029	.445	2.007	13.137	
	Zt35	.034	.495	10.136	11.712	
	Zt36	.038	.997	7.693	11.983	
	Zt55	.059	.549	13.849	10.693	
	Zt56	.022	1.380	13.339	10.654	
	Zt58	.042	1.401	15.468	10.172	
	Zt59	.060	.820	16.043	10.220	
Hidden Unit Width		.337	8.560	21.756	29.298	
Hidden Layer	(Intercept)					12.168
	H(1)					-2.126
	H(2)					-4.335
	H(3)					-29.604
	H(4)					7.178

a. Displays the center vector for each hidden unit.

4) 5 Node

Model Summary

Training	Sum of Squares Error	74627.774
	Relative Error	.873
	Training Time	0:00:00.00
Testing	Sum of Squares Error	9377.870
	Relative Error	.983

Dependent Variable: Zt

Lampiran 11. *Output Software* RBFNN (Lanjutan)

Parameter Estimates

Predictor		Predicted					
		Hidden Layer[a]					Output Layer
		H(1)	H(2)	H(3)	H(4)	H(5)	Zt
Input Layer	Zt1	.032	3.924	.217	12.372	16.650	
	Zt2	.055	3.759	.470	12.513	15.952	
	Zt9	.028	3.780	.945	14.143	5.602	
	Zt10	.013	4.152	.532	14.508	3.064	
	Zt12	.020	1.106	1.404	14.672	5.471	
	Zt13	.029	.445	2.007	13.131	13.170	
	Zt35	.034	.495	10.136	13.152	4.437	
	Zt36	.038	.997	7.693	12.990	6.896	
	Zt55	.059	.549	13.849	12.640	.854	
	Zt56	.022	1.380	13.339	12.451	1.573	
	Zt58	.042	1.401	15.468	12.121	.320	
	Zt59	.060	.820	16.043	12.191	.261	
Hidden Unit Width		.337	8.560	21.756	30.567	18.252	
Hidden Layer	(Intercept)						12.521
	H(1)						-1.963
	H(2)						-5.945
	H(3)						-28.544
	H(4)						2.836
	H(5)						6.546

a. Displays the center vector for each hidden unit.

5) 6 Node

Model Summary

Training	Sum of Squares Error	74555.571
	Relative Error	.872
	Training Time	0:00:00.00
Testing	Sum of Squares Error	9372.592
	Relative Error	.982

Dependent Variable: Zt

Lampiran 11. *Output Software* RBFNN (Lanjutan)

Parameter Estimates

Predictor		Predicted						
		Hidden Layer[a]						Output Layer
		H(1)	H(2)	H(3)	H(4)	H(5)	H(6)	Zt
Input Layer	Zt1	.032	.561	.217	12.372	6.866	16.650	
	Zt2	.055	.522	.470	12.513	6.591	15.952	
	Zt9	.028	.452	.945	14.143	6.693	5.602	
	Zt10	.013	.862	.532	14.508	7.030	3.064	
	Zt12	.020	.612	1.404	14.672	1.538	5.471	
	Zt13	.029	.153	2.007	13.131	.700	13.170	
	Zt35	.034	.814	10.136	13.152	.216	4.437	
	Zt36	.038	2.012	7.693	12.990	.109	6.896	
	Zt55	.059	.922	13.849	12.640	.221	.854	
	Zt56	.022	2.756	13.339	12.451	.175	1.573	
	Zt58	.042	1.487	15.468	12.121	1.327	.320	
	Zt59	.060	1.363	16.043	12.191	.345	.261	
Hidden Unit Width		.337	4.098	21.756	30.567	10.457	18.252	
Hidden Layer	(Intercept)							12.555
	H(1)							-1.871
	H(2)							-1.273
	H(3)							-28.171
	H(4)							2.279
	H(5)							-9.078
	H(6)							9.225

a. Displays the center vector for each hidden unit.

Lampiran 12. Surat Pernyataan Keaslian Data Curah Hujan di Stasiun Juanda

SURAT PERNYATAAN

Saya yang bertanda tangan dibawah ini, mahasiswa Departemen Statistika Bisnis Fakultas Vokasi ITS :

Nama : OcktaliaTrisnawati
NRP : 10611710000115

Menyatakan bahwa data yang digunakan dalam Proyek Akhir yang berjudul "**Peramalan Curah Hujan di Stasiun Juanda Menggunakan Metode ARIMA *Box-Jenkins* dan *Radial Basis Function Neural Network***" merupakan data sekunder yang diambil dari Data Online Pusat Database - BMKG :

Sumber : *dataonline.bmkg.go.id*
Keterangan : Data yang digunakan merupakan data curah hujan Januari 2019 hingga April 2021.

Surat pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data, maka saya siap menerima sanksi sesuai dengan peraturan yang berlaku.

Surabaya, 14 Juni 2021

Pembimbing Proyek Akhir	Yang menyatakan
Mike Prastuti, S.Si, M.Si.	(Ocktalia Trisnawati)
NIP. 19910122 201504 2 002	NRP. 10611710000039

BIODATA PENULIS

Penulis bernama Ocktalia Trisnawati lahir di Sidoarjo, 16 Oktober 1999. Penulis merupakan anak bungsu dari satu bersaudara. Dari kecil penulis menempuh pendidikan formal di Surabaya. SDN Sumur Welut III/440, SMPN 24 Surabaya, SMAN 13 Surabaya dan sekarang sedang menyelesaikan studi sarjana terapan di Departemen Statistika Bisnis ITS. Penulis merupakan angkatan 2017 atau bisa dikenal dengan "INFINITY" yang bisa disebut keluarga kedua. Pada semester 4 hingga semester 6 penulis mengikuti kegiatan organisasi DPM Fakultas Vokasi. Semester 4 pernah Kerja Praktik selama 1 bulan di RS Islam A.Yani Surabaya dibidang Rekam Medis. Semester 6 penulis melaksanakan kegiatan Magang selama 4 bulan di Dinas Penanaman Modal & PTSP Kota Surabaya seksi Data & Informasi Penanaman Modal. Jika ingin berdiskusi mengenai Proyek Akhir dapat menghubungi melalui *email oktalia19@gmail.com*.