



TUGAS AKHIR - KS184822

**PERAMALAN PRODUKTIVITAS BUAH YANG  
DIPENGARUHI SUHU, CURAH HUJAN, DAN  
KELEMBABAN DI KOTA BATU DENGAN METODE  
STATISTIK DAN *MACHINE LEARNING***

**INDANA LAZULFA SETYOBUDI  
NRP 062117 4500 0010**

**Dosen Pembimbing  
Santi Puteri Rahayu, M.Si., Ph.D.  
Dr. Suhartono**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2019**



**TUGAS AKHIR - KS184822**

**PERAMALAN PRODUKTIVITAS BUAH YANG  
DIPENGARUHI SUHU, CURAH HUJAN, DAN  
KELEMBABAN DI KOTA BATU DENGAN METODE  
STATISTIK DAN *MACHINE LEARNING***

**INDANA LAZULFA SETYOBUDI  
NRP 062117 4500 0010**

**Dosen Pembimbing  
Santi Puteri Rahayu, M.Si., Ph.D.  
Dr. Suhartono**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2019**



**FINAL PROJECT - KS184822**

**FORECASTING PRODUCTIVITY OF FRUITS  
INFLUENCED BY TEMPERATURE, RAINFALL, AND  
HUMIDITY IN BATU CITY USE STATISTICAL  
METHOD AND MACHINE LEARNING**

**INDANA LAZULFA SETYOBUDI  
SN 062117 4500 0010**

**Supervisors  
Santi Puteri Rahayu, M.Si., Ph.D.  
Dr. Suhartono**

**UNDERGRADUATE PROGRAMME  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2019**

**LEMBAR PENGESAHAN**

**PERAMALAN PRODUKTIVITAS BUAH YANG  
DIPENGARUHI SUHU, CURAH HUJAN, DAN  
KELEMBABAN DENGAN METODE STATISTIK DAN  
MACHINE LEARNING**

**TUGAS AKHIR**

Diajukan untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Statistika  
pada

Program Studi Sarjana Departemen Statistika  
Fakultas Matematika, Komputasi, dan Sains Data  
Institut Teknologi Sepuluh Nopember

Oleh :

**Indana Lazulfa Setyobudi**  
NRP. 062117 4500 0010

Disetujui oleh Pembimbing:  
**Santi Puteri Rahayu, M.Si., Ph.D.**  
NIP. 19750115 199903 2 003

(  )

**Dr. Suhartono**  
NIP. 19710929 199512 1 001

(  )



Mengetahui,  
Kepala Departemen Statistika



**Dr. Suhartono**  
NIP. 19710929 199512 1 001

SURABAYA, JULI 2019

**PERAMALAN PRODUKTIVITAS BUAH YANG  
DIPENGARUHI SUHU, CURAH HUJAN, DAN  
KELEMBABAN DI KOTA BATU DENGAN METODE  
STATISTIK DAN *MACHINE LEARNING***

**Nama** : Indana Lazulfa Setyobudi  
**NRP** : 06211745000010  
**Departemen** : Statistika  
**Dosen Pembimbing** : Santi Puteri Rahayu, M.Si., Ph.D.  
Dr. Suhartono

**Abstrak**

*Kota Batu juga dikenal sebagai kota penghasil buah, dimana produksi buah apel menurun akhi-akhir ini. Namun buah lain mengalami kenaikan diantaranya jeruk siam/keprok, alpukat, jambu biji, dan pisang. Penurunan produksi apel tersebut diduga akibat berubahnya iklim dan hujan yang terus menerus. Tujuan penelitian ini adalah meramalkan produktivitas buah yang diduga dipengaruhi suhu, curah hujan, dan kelembaban di Kota Batu. Metode yang digunakan pada penelitian ini adalah ARIMA, fungsi transfer, dan FFNN. Variabel dependen yang digunakan yaitu produktivitas buah, sedangkan variabel independen yang digunakan adalah suhu, curah hujan, dan kelembaban. Data yang digunakan berupa data triwulan pada periode Januari 2008 sampai Desember 2018. Berdasarkan hasil analisis diperoleh bahwa model terbaik untuk meramalkan produktivitas buah adalah dengan metode FFNN. Hasil analisis juga menunjukkan bahwa produktivitas apel, jambu biji, dan alpukat dipengaruhi oleh curah hujan. Sedangkan produktivitas jeruk dipengaruhi suhu. Hasil peramalan menunjukkan bahwa produktivitas jeruk, alpukat, dan pisang di Kota Batu diprediksi mengalami peningkatan di tahun 2019, sedangkan produktivitas apel dan jambu biji mengalami penurunan.*

**Kata kunci :** *Peramalan, produktivitas, suhu, curah hujan, kelembaban, ARIMA, fungsi transfer, FFNN.*

*Halaman ini sengaja dikosongkan*

**FORECASTING PRODUCTIVITY OF FRUITS  
INFLUENCED BY TEMPERATURE, RAINFALL, AND  
HUMIDITY IN BATU CITY USE STATISTICAL METHOD  
AND MACHINE LEARNING**

**Student Name** : Indana Lazulfa Setyobudi  
**Student Number** : 06211745000010  
**Department** : Statistics  
**Supervisors** : Santi Puteri Rahayu, M.Si., Ph.D.  
Dr. Suhartono

**Abstract**

*Batu City also known as apples producer, where the apples production is decreasing recently. But, another fruits are increasing, there are oranges, avocados, guavas, and bananas. Decrease of apples production is suspected because climate change and unstinting rain. The purpose of this research is predicting fruits productivity which depends on temperature, rainfall, and humidity in Batu. The methods which are used in this research is ARIMA, transfer function, and FFNN. Fruits productivity is used to be dependent variabel, while the used independent variabel is temperature, rainfall, and humidity. The used data is quarterly data on January 2008 until December 2018. Based on analysis can be inferred that the best model for predicting fruits productivity is FFNN mode. The result of analysis shows that rainfall influence apples, avocados, and guavas productivity. While oranges productivity is influenced by temperature. The results of prediction shows that oranges, avocados, and bananas productivity in Batu City are predicted to have increase in 2019, meanwhile apples and guavas productivity has decrease.*

**Keywords :** *Forecasting, productivity, temperature, rainfall, humidity, ARIMA, transfer function, FFNN.*

*Halaman ini sengaja dikosongkan*

## KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Allah SWT karena dengan rahmat, karunia, serta taufik dan hidayah-Nya penulis dapat menyelesaikan laporan Tugas Akhir dengan judul “Peramalan Produktivitas Buah yang Dipengaruhi Suhu, Curah Hujan, dan Kelembaban di Kota Batu dengan Metode Statistik dan *Machine Learning*”.

Laporan Tugas Akhir ini dapat terselesaikan dengan baik atas bantuan dan dukungan dari berbagai pihak baik secara langsung maupun tidak langsung. Oleh karena itu, penulis ingin mengucapkan terima kasih kepada:

1. Ibu Santi Puteri Rahayu, M.Si., Ph.D. dan Dr. Suhartono, M.Sc. selaku dosen pembimbing yang telah membimbing dalam pelaksanaan Tugas Akhir serta penyusunan laporan Tugas Akhir.
2. Bapak Dr. rer. pol. Heri Kuswanto, S.Si., M.Si. dan Bapak M. Sjahid Akbar, S.Si., M.Si. selaku dosen penguji yang telah memberikan saran dan kritik yang membangun untuk menyempurnakan Tugas Akhir.
3. Segenap Dosen dan karyawan Departemen Statistika Fakultas Matematika, Komputasi, dan Sains Data atas semua kebaikan yang diberikan.
4. Dinas Pertanian dan Kehutanan Kota Batu yang sudah memperkenankan penulis untuk mengambil data untuk keperluan Tugas Akhir.
5. Pimpinan Kepala Badan Meteorologi, Klimatologi, dan Geofisika Karangploso, Malang yang sudah memberikan ijin penulis untuk mengambil data dalam keperluan Tugas Akhir.
6. Segenap karyawan Badan Meteorologi, Klimatologi, dan Geofisika Karangploso, Malang yang telah membantu penulis untuk mengambil data dalam keperluan Tugas Akhir.
7. Orang tua dan keluarga penulis yang selalu memberikan motivasi, dukungan dan doa dalam segala proses Tugas Akhir

dan semua pihak yang tidak mungkin penulis sebutkan satu per satu.

Penulis menyadari masih banyak kekurangan dalam Tugas Akhir ini, maka segala kritik dan saran sangat dibutuhkan untuk perbaikan. Semoga Tugas Akhir ini dapat bermanfaat bagi penulis, pembaca, dan juga pihak yang berkepentingan.

Surabaya, Juli 2019

Penulis

# DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL</b> .....	i
<b>COVER PAGE</b> .....	iii
<b>LEMBAR PENGESAHAN</b> .....	v
<b>ABSTRAK</b> .....	vii
<b>ABSTRACT</b> .....	ix
<b>KATA PENGANTAR</b> .....	xi
<b>DAFTAR ISI</b> .....	xiii
<b>DAFTAR TABEL</b> .....	xv
<b>DAFTAR GAMBAR</b> .....	xvii
<b>BAB I PENDAHULUAN</b>	
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	5
1.3 Tujuan .....	6
1.4 Ruang Lingkup / Batasan Masalah .....	6
1.5 Manfaat Penelitian .....	6
<b>BAB II TINJAUAN PUSTAKA</b>	
2.1 <i>Time Series Analysis</i> .....	7
2.2 <i>Autoregressive Integrated Moving Average</i> (ARIMA) .....	7
2.3 Model Fungsi Transfer .....	9
2.4 Pengujian Linieritas .....	12
2.5 <i>Feedforward Neural Network</i> (FFNN) .....	13
2.6 Pemilihan Model Terbaik .....	18
2.7 Tinjauan Non Statistik .....	19
<b>BAB III METODOLOGI PENELITIAN</b>	
3.1 Sumber Data dan Variabel Penelitian .....	21
3.2 Variabel Penelitian .....	21
3.3 Langkah Analisis .....	22
<b>BAB IV ANALISIS DAN PEMBAHASAN</b>	
4.1 Karakteristik Data Iklim dan Produktivitas Buah di Kota Batu .....	29

4.2	Pemodelan Produktivitas Lima Buah di Kota Batu ....	39
4.2.1	Pemodelan Produktivitas Lima Buah di Kota Batu dengan Metode ARIMA.....	40
4.2.2	Pemodelan Produktivitas Lima Buah di Kota Batu dengan Metode Fungsi Transfer.....	54
4.2.3	Pengujian Linieritas pada Data Produktivitas Lima Buah di Kota Batu.....	87
4.2.4	Pemodelan Produktivitas Lima Buah di Kota Batu dengan Metode FFNN.....	87
4.3	Pemilihan Model Terbaik dan Peramalan Produktivitas Buah di Kota Batu.....	102

## **BAB V KESIMPULAN DAN SARAN**

5.1	Kesimpulan .....	105
5.2	Saran .....	105

## **DAFTAR PUSTAKA**

## **LAMPIRAN**

## **BIODATA PENULIS**

## DAFTAR TABEL

	Halaman
<b>Tabel 3.1</b> Variabel Penelitian.....	21
<b>Tabel 3.2</b> Struktur Data.....	22
<b>Tabel 4.1</b> Karakteristik Data Keseluruhan .....	29
<b>Tabel 4.2</b> Pengujian Parameter Model ARIMA pada Produktivitas Apel .....	42
<b>Tabel 4.3</b> Pemilihan Model ARIMA Terbaik pada Produktivitas Apel .....	43
<b>Tabel 4.4</b> Pengujian Parameter Model ARIMA pada Produktivitas Jeruk.....	45
<b>Tabel 4.5</b> Pemilihan Model ARIMA Terbaik pada Produktivitas Jeruk.....	45
<b>Tabel 4.6</b> Pengujian Parameter Model ARIMA pada Produktivitas Alpukat .....	47
<b>Tabel 4.7</b> Pemilihan Model ARIMA Terbaik pada Produktivitas Alpukat .....	48
<b>Tabel 4.8</b> Pengujian Parameter Model ARIMA pada Produktivitas Jambu Biji.....	50
<b>Tabel 4.9</b> Pemilihan Model ARIMA Terbaik pada Produktivitas Jambu Biji.....	50
<b>Tabel 4.10</b> Pengujian Parameter Model ARIMA pada Produktivitas Pisang.....	53
<b>Tabel 4.11</b> Pemilihan Model ARIMA Terbaik pada Produktivitas Pisang.....	53
<b>Tabel 4.12</b> Pengujian Parameter Model ARIMA pada Suhu Rata-rata.....	55
<b>Tabel 4.13</b> Pemilihan Model ARIMA Terbaik pada Suhu .....	56
<b>Tabel 4.14</b> Pengujian Parameter Model ARIMA pada Kelembaban .....	58
<b>Tabel 4.15</b> Pemilihan Model ARIMA Terbaik pada Kelembaban .....	59
<b>Tabel 4.16</b> Pengujian Parameter Model ARIMA pada Curah Hujan.....	61

<b>Tabel 4.17</b>	Pengujian Parameter Model Fungsi Transfer Suhu dan Produktivitas Apel.....	63
<b>Tabel 4.18</b>	Pengujian Parameter Model Fungsi Transfer Kelembaban dan Produktivitas Apel.....	65
<b>Tabel 4.19</b>	Pengujian Parameter Model Fungsi Transfer Curah Hujan dan Produktivitas Apel.....	67
<b>Tabel 4.20</b>	Pengujian Parameter Model Fungsi Transfer Suhu dan Produktivitas Jeruk.....	69
<b>Tabel 4.21</b>	Pengujian Parameter Model Fungsi Transfer Suhu dan Produktivitas Alpukat.....	72
<b>Tabel 4.22</b>	Pengujian Parameter Model Fungsi Transfer Kelembaban dan Produktivitas Alpukat.....	74
<b>Tabel 4.23</b>	Pengujian Parameter Model Fungsi Transfer Curah Hujan dan Produktivitas Alpukat.....	76
<b>Tabel 4.24</b>	Pengujian Parameter Model Fungsi Transfer Suhu dan Produktivitas Jambu Biji .....	78
<b>Tabel 4.25</b>	Pengujian Parameter Model Fungsi Transfer Kelembaban dan Produktivitas Jambu Biji .....	80
<b>Tabel 4.26</b>	Pengujian Parameter Model Fungsi Transfer Curah Hujan dan Produktivitas Jambu Biji .....	81
<b>Tabel 4.27</b>	Pemilihan Model Terbaik Metode Fungsi Transfer.....	85
<b>Tabel 4.28</b>	Uji Linieritas Produktivitas Buah.....	87
<b>Tabel 4.29</b>	Nilai SSE Pemodelan FFNN pada Produktivitas Apel .....	88
<b>Tabel 4.30</b>	Nilai SSE Pemodelan FFNN pada Produktivitas Jeruk .....	91
<b>Tabel 4.31</b>	Nilai SSE Pemodelan FFNN pada Produktivitas Alpukat .....	94
<b>Tabel 4.32</b>	Nilai SSE Pemodelan FFNN pada Produktivitas Jambu Biji.....	97
<b>Tabel 4.33</b>	Nilai SSE Pemodelan FFNN pada Produktivitas Pisang .....	100
<b>Tabel 4.34</b>	Pemilihan Model Terbaik.....	102
<b>Tabel 4.35</b>	Peramalan Produktivitas Buah tahun 2019.....	103

## DAFTAR GAMBAR

	Halaman
<b>Gambar 2.1</b> Arsitektur FFNN dengan satu <i>hidden layer</i> , $p$ unit input, $q$ unit neuron di <i>hidden layer</i> , dan satu unit neuron output.....	14
<b>Gambar 3.1</b> Diagram Alir Penelitian.....	25
<b>Gambar 3.2</b> Tahapan Pemodelan ARIMA .....	26
<b>Gambar 3.3</b> Tahapan Pemodelan Fungsi Transfer.....	27
<b>Gambar 3.4</b> Tahapan Pemodelan FFNN .....	28
<b>Gambar 4.1</b> Karakteristik Suhu Rata-rata, Suhu Maksimum, Kelembaban, dan Curah Hujan di Kota Batu.....	30
<b>Gambar 4.2</b> Karakteristik Suhu Rata-rata tiap Tahun di Kota Batu .....	31
<b>Gambar 4.3</b> Karakteristik Suhu Maksimum tiap Tahun di Kota Batu .....	31
<b>Gambar 4.4</b> Karakteristik Kelembaban tiap Tahun di Kota Batu .....	33
<b>Gambar 4.5</b> Karakteristik Curah Hujan tiap Tahun di Kota Batu .....	33
<b>Gambar 4.6</b> Karakteristik Produktivitas Lima Buah di Kota Batu .....	34
<b>Gambar 4.7</b> Karakteristik Produktivitas Apel di Kota Batu ....	35
<b>Gambar 4.8</b> Karakteristik Produktivitas Jeruk di Kota Batu ...	36
<b>Gambar 4.9</b> Karakteristik Produktivitas Alpukat di Kota Batu .....	37
<b>Gambar 4.10</b> Karakteristik Produktivitas Jambu Biji di Kota Batu .....	38
<b>Gambar 4.11</b> Karakteristik Produktivitas Pisang di Kota Batu .....	38
<b>Gambar 4.12</b> Analisis Hubungan Deret Input dan Deret Output.....	39
<b>Gambar 4.13</b> <i>Time Series Plot</i> Produktivitas Apel .....	40
<b>Gambar 4.14</b> <i>Transformasi Box Cox</i> Produktivitas Apel .....	41
<b>Gambar 4.15</b> Plot (a) ACF (b) PACF Produktivitas Apel .....	41

<b>Gambar 4.16</b>	Plot (a) ACF (b) PACF Produktivitas Apel Setelah <i>Differencing</i> .....	42
<b>Gambar 4.17</b>	<i>Time Series Plot</i> Produktivitas Jeruk .....	43
<b>Gambar 4.18</b>	<i>Transformasi Box Cox</i> Produktivitas Jeruk .....	44
<b>Gambar 4.19</b>	Plot (a) ACF (b) PACF Produktivitas Jeruk .....	44
<b>Gambar 4.20</b>	<i>Time Series Plot</i> Produktivitas Alpukat .....	46
<b>Gambar 4.21</b>	<i>Transformasi Box Cox</i> Produktivitas Alpukat .....	46
<b>Gambar 4.22</b>	Plot (a) ACF (b) PACF Produktivitas Alpukat .....	47
<b>Gambar 4.23</b>	<i>Time Series Plot</i> Produktivitas Jambu Biji .....	48
<b>Gambar 4.24</b>	<i>Transformasi Box Cox</i> Produktivitas Jambu Biji .....	49
<b>Gambar 4.25</b>	Plot (a) ACF (b) PACF Produktivitas Jambu Biji .....	49
<b>Gambar 4.26</b>	<i>Time Series Plot</i> Produktivitas Pisang .....	51
<b>Gambar 4.27</b>	<i>Transformasi Box Cox</i> Produktivitas Pisang .....	51
<b>Gambar 4.28</b>	Plot (a) ACF (b) PACF Produktivitas Pisang .....	52
<b>Gambar 4.29</b>	Plot (a) ACF (b) PACF Produktivitas Pisang Setelah <i>Differencing</i> .....	52
<b>Gambar 4.30</b>	<i>Time Series Plot</i> Suhu Rata-rata .....	54
<b>Gambar 4.31</b>	Plot (a) ACF (b) PACF Suhu Rata-rata .....	54
<b>Gambar 4.32</b>	Plot (a) ACF (b) PACF Suhu Rata-rata Setelah <i>Differencing</i> .....	55
<b>Gambar 4.33</b>	<i>Time Series Plot</i> Kelembaban .....	57
<b>Gambar 4.34</b>	Plot (a) ACF (b) PACF Kelembaban .....	57
<b>Gambar 4.35</b>	Plot (a) ACF (b) PACF Kelembaban Setelah <i>Differencing</i> .....	58
<b>Gambar 4.36</b>	<i>Time Series Plot</i> Curah Hujan .....	60
<b>Gambar 4.37</b>	Plot (a) ACF (b) PACF Curah Hujan .....	60
<b>Gambar 4.38</b>	Plot (a) ACF (b) PACF Curah Hujan Setelah <i>Differencing</i> .....	61

<b>Gambar 4.39</b>	CCF Produktivitas Apel dan Suhu Rata-rata .....	62
<b>Gambar 4.40</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Apel dan Suhu Rata-rata.....	63
<b>Gambar 4.41</b>	CCF Produktivitas Apel dan Kelembaban.....	64
<b>Gambar 4.42</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Apel dan Kelembaban .....	65
<b>Gambar 4.43</b>	CCF Produktivitas Apel dan Curah Hujan .....	66
<b>Gambar 4.44</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Apel dan Curah Hujan .....	67
<b>Gambar 4.45</b>	CCF Produktivitas Jeruk dan Suhu Rata-rata .....	68
<b>Gambar 4.46</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Jeruk dan Suhu Rata-rata .....	69
<b>Gambar 4.47</b>	CCF Produktivitas Jeruk dan Kelembaban.....	70
<b>Gambar 4.48</b>	CCF Produktivitas Jeruk dan Curah Hujan.....	71
<b>Gambar 4.49</b>	CCF Produktivitas Alpukat dan Suhu .....	72
<b>Gambar 4.50</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Alpukat dan Suhu Rata-rata.....	72
<b>Gambar 4.51</b>	CCF Produktivitas Alpukat dan Kelembaban.....	73
<b>Gambar 4.52</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Alpukat dan Kelembaban .....	74
<b>Gambar 4.53</b>	CCF Produktivitas Alpukat dan Curah Hujan .....	75
<b>Gambar 4.54</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Alpukat dan Curah Hujan .....	76
<b>Gambar 4.55</b>	CCF Produktivitas Jambu Biji dan Suhu .....	77
<b>Gambar 4.56</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Jambu Biji dan Suhu Rata-rata .....	78
<b>Gambar 4.57</b>	CCF Produktivitas Jambu Biji dan Kelembaban.....	79
<b>Gambar 4.58</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Jambu Biji dan Kelembaban.....	79
<b>Gambar 4.59</b>	CCF Produktivitas Jambu Biji dan Curah Hujan.....	81
<b>Gambar 4.60</b>	Plot ACF dan PACF Deret <i>Noise</i> Pemodelan Produktivitas Jambu Biji dan Curah Hujan.....	81
<b>Gambar 4.61</b>	CCF Produktivitas Pisang dan Suhu Rata-rata .....	82

<b>Gambar 4.62</b>	CCF Produktivitas Pisang dan Kelembaban.....	83
<b>Gambar 4.63</b>	CCF Produktivitas Pisang dan Curah Hujan.....	84
<b>Gambar 4.64</b>	Arsitektur FFNN(9,2,1) Produktivitas Apel .....	89
<b>Gambar 4.65</b>	<i>Plot Time Series</i> Perbandingan (a) Data <i>Training</i> dan <i>Fits</i> (b) Data <i>Testing</i> dan Hasil Ramalan Model FFNN Produktivitas Apel.....	90
<b>Gambar 4.66</b>	Arsitektur FFNN(11,6,1) Produktivitas Jeruk.....	92
<b>Gambar 4.67</b>	<i>Plot Time Series</i> Perbandingan (a) Data <i>Training</i> dan <i>Fits</i> (b) Data <i>Testing</i> dan Hasil Ramalan Model FFNN Produktivitas Jeruk.....	93
<b>Gambar 4.68</b>	Arsitektur FFNN(11,1,1) Produktivitas Alpukat.....	95
<b>Gambar 4.69</b>	<i>Plot Time Series</i> Perbandingan (a) Data <i>Training</i> dan <i>Fits</i> (b) Data <i>Testing</i> dan Hasil Ramalan Model FFNN Produktivitas Alpukat.....	96
<b>Gambar 4.70</b>	Arsitektur FFNN(2,10,1) Produktivitas Jambu Biji.....	98
<b>Gambar 4.71</b>	<i>Plot Time Series</i> Perbandingan (a) Data <i>Training</i> dan <i>Fits</i> (b) Data <i>Testing</i> dan Hasil Ramalan Model FFNN Produktivitas Jambu Biji .....	99
<b>Gambar 4.72</b>	Arsitektur FFNN(3,3,1) Produktivitas Pisang....	101
<b>Gambar 4.73</b>	<i>Plot Time Series</i> Perbandingan (a) Data <i>Training</i> dan <i>Fits</i> (b) Data <i>Testing</i> dan Hasil Ramalan Model FFNN Produktivitas Pisang.....	101
<b>Gambar 4.74</b>	<i>Plot Time Series</i> Produktivitas Buah dan Hasil Ramalan.....	104

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Belakangan ini perubahan iklim telah menjadi isu penting yang mengakibatkan kenaikan suhu rata-rata global, perubahan pola curah hujan, kenaikan muka air laut, dan peningkatan intensitas cuaca ekstrim. Panel on Climate Change-IPCC (2007) telah melakukan kajian dengan hasil bahwa telah terjadi perubahan iklim dengan indikasi adanya kenaikan suhu rata-rata global untuk periode 1899 sampai 2005 sebesar  $0,76^{\circ}\text{C}$ , kenaikan muka air laut rata-rata global periode 1961 sampai 2003 sebesar 1,8mm, meningkatnya ketidakpastian intensitas hujan, meningkatnya banjir, kekeringan, dan erosi, dan meningkatnya fenomena ekstrim seperti *El Nino*, *La Nina*, siklon, puting beliung, dan *hailstone*. Perubahan iklim ini menyebabkan perubahan pula pada tata air/sumber daya air dan pertanian.

Penelitian dilakukan di 13 stasiun Klimatologi, menghasilkan pernyataan bahwa terjadinya perubahan iklim di Indonesia yang diindikasikan peningkatan jumlah curah hujan tahunan di wilayah timur Indonesia berkisar antara 490 mm/tahun (Sulawesi Selatan) sampai 1400 mm/tahun (Jawa Timur). Peningkatan tersebut diikuti oleh meningkatnya suhu pada siang dan malam hari yaitu antara  $0,5-1,1^{\circ}\text{C}$  dan  $0,6-2,3^{\circ}\text{C}$ . Sedangkan di wilayah barat Indonesia terjadi sebaliknya, dimana terdapat tendensi penurunan curah hujan tahunan sekitar 135 hingga 860 mm/tahun, dengan peningkatan suhu siang dan malam hari antara  $0,2-0,4^{\circ}\text{C}$  dan  $0,2-0,7^{\circ}\text{C}$ . Perubahan iklim global tersebut juga sejalan dengan makin cepatnya periode *El Nino* dimana melanda Indonesia 2-3 tahun sekali, dimana dulunya melanda Indonesia 5 sampai 6 tahun sekali (Syahbuddin, Manabu, & Eleonora, 2004).

Penelitian juga dilakukan pada perubahan iklim di wilayah Malang Raya menunjukkan bahwa suhu meningkat sebesar  $0,7$  sampai  $0,8^{\circ}\text{C}$  dan curah hujan menurun sebesar 0-55 mm (Ruminta & Handoko, 2011). Perubahan iklim tersebut dapat mengancam produksi pertanian termasuk produksi tanaman apel

di Kota Batu. Apalagi perubahan iklim tersebut juga mengancam mata pencaharian petani khususnya petani apel. Pertanian merupakan sektor yang cukup rentan terhadap perubahan iklim karena ketergantungannya yang tinggi pada iklim dan cuaca.

Penelitian dilakukan oleh Faulina (2014) yang bertujuan untuk memperkirakan curah hujan, sehingga dapat digunakan untuk menentukan kalender tanam budidaya apel. Penelitian tersebut menggunakan metode ARIMA dan *ensemble* ARIMA. Curah hujan antar tempat mempunyai sifat dan karakteristik yang berbeda satu sama lainnya. Hal tersebut bergantung pada letak geografis, letak topografi, dan ketinggian. Sehingga penelitian dilakukan terhadap enam titik stasiun yang berbeda di Kota Batu. Hasil penelitian menunjukkan bahwa dengan model ARIMA maupun *ensemble* ARIMA terdapat kemiripan pola curah hujan untuk keenam stasiun tersebut.

Salah satu daerah di Jawa Timur yang mengembangkan tanaman buah apel secara luas adalah Kota Batu. Perkebunan apel di daerah tersebut dikembangkan sejak tahun 1950 dan berkembang pesat sejak tahun 1990-an hingga saat ini. Hal tersebut karena ditopang oleh kondisi topografis yang sangat cocok untuk kegiatan di sektor pertanian. Tanaman apel sendiri dapat tumbuh dan berbuah dengan baik di daerah dataran tinggi yang memiliki temperatur rendah, kelembapan udara yang rendah, dan curah hujan yang tidak terlalu tinggi (Soelarso, 1996). Kota Batu merupakan salah satu daerah yang berada di Malang Raya, hasil pemekaran dari Kabupaten Malang bagian utara. Kota ini memiliki panorama yang indah, dengan cuaca yang dingin dan sejuk. Selain itu Kota Batu juga dikenal sebagai kota penghasil apel, yang menjadi unggulan di bidang pertanian.

Panen apel di Kota Batu akhir-akhir ini mengalami penurunan. Pada tahun 2014 produksi buah apel sebesar 708.438 kwintal, sedangkan pada tahun 2015 mengalami penurunan sebesar 5,25% menjadi 671.207 kwintal. Pada tahun 2016 produksi apel juga mengalami penurunan sebesar 19,2% menjadi 542.106 kwintal (Badan Pusat Statistik Kota Batu, 2017).

Penurunan produksi apel tersebut diduga akibat berubahnya iklim dan beberapa faktor non-iklim. Petani apel juga menilai bahwa penurunan panen apel akhir-akhir ini disebabkan karena perubahan suhu dan hujan yang terus menerus (Sitompul, 2007).

Selain apel, Kota Batu juga memiliki tanaman lain yang banyak diusahakan, antara lain jeruk siam/keprok, alpukat, jambu biji, dan pisang. Produksi keempat buah tersebut mengalami kenaikan dari tahun 2013 sampai tahun 2017. Pada tahun 2017 produksi jeruk siam/keprok sebesar 187.045 kwintal, produksi alpukat sebesar 54.591 kwintal, produksi jambu biji sebesar 22.622 kwintal, dan produksi pisang sebesar 11.416 kwintal (Badan Pusat Statistik Kota Batu, 2017).

Penelitian dilakukan oleh Ibrahim dkk. (2016) tentang keputusan petani tetap menanam apel di Desa Pungging, Kec. Nongkojajar, Kab. Pasuruan dengan metode regresi linear berganda. Hasilnya menyatakan bahwa faktor-faktor yang mempengaruhi petani tetap menanam apel adalah produktivitas apel, pemasaran apel, harga sarana produksi, dan luas lahan garapan.

Penelitian tentang apel juga dilakukan oleh Aditiyas dkk (2005) tentang analisis spasial untuk evaluasi kesesuaian lahan tanaman apel di Kota Batu. Hasilnya menyatakan bahwa kesesuaian lahan untuk tanaman apel dengan kategori sangat sesuai sekitar 89,92% dari luas wilayah Kota Batu secara keseluruhan. Berarti sebagian besar daerah di Kota Batu cocok untuk tanaman apel. Berikut merupakan desa-desa yang sangat sesuai untuk tanaman apel yaitu desa Sumber Brantas, Sumbergondo, Tulungrejo, Punten, Bulukerto, Gunungsari, Sidomulyo, Bumiaji, Sumberejo, Pandanrejo, Giripurno, Ngaglik, Songgokerto, Pendem, Mojorejo, Tlekung, dan Oro-oro ombo.

*Neural network* adalah model yang terinspirasi oleh sistem saraf biologis. *Neural network* terdiri dari unsur-unsur sederhana yang beroperasi secara paralel. Seperti di alam, hubungan antara unsur-unsur sangat menentukan fungsi jaringan. Jaringan pada *neural network* dilatih untuk melakukan fungsi tertentu dengan menyesuaikan nilai-nilai dari koneksi (bobot) antar unsur-unsur.

Biasanya, *neural network* disesuaikan atau dilatih sehingga *input* tertentu menyebabkan *output* target tertentu (Beale & Hudson, 2010).

Metode *Feedforward Neural Network* (FFNN) adalah salah satu metode *neural network* yang sering digunakan dalam melakukan prediksi. Menurut Suhartono (2007), FFNN dapat dipandang sebagai suatu kelas yang fleksibel dari fungsi-fungsi nonlinier. Jaringan pada model FFNN menggunakan algoritma *backpropagation*. William dan Li pada tahun 1998 telah meneliti penggunaan *neural network* dengan algoritma *backpropagation* untuk memprediksi pacuan kuda di Jamaika. *Neural network* dengan algoritma *backpropagation* yang digunakan dalam penelitian ini telah terbukti memberikan hasil prediksi yang baik (Farber & Lapedes, 2008). Diantara berbagai model *neural network*, FFNN merupakan model yang lebih sering digunakan karena dikenal memiliki kemampuan pendekatan yang baik dan bersifat universal (Handaga & Asy'ari, 2012). Selain itu, metode ini telah terkenal akan keunggulannya yaitu memiliki nilai prediksi yang sangat mendekati nilai aktualnya sehingga menghasilkan *error* yang kecil serta memiliki kemampuan untuk mendeteksi atau melakukan analisis untuk permasalahan yang sifatnya sangat kompleks. Metode ini juga tidak memiliki syarat atau asumsi tertentu (Setiawan, 2008).

Penelitian sebelumnya pernah dilakukan oleh Syarifah (2018) yang melakukan peramalan terhadap penjualan pertamax dengan metode ARIMAX, FFNN, dan *hybrid* ARIMAX-FFNN. Diperoleh hasil bahwa model FFNN menunjukkan nilai RMSEP minimum, sehingga dapat dikatakan bahwa model FFNN merupakan model terbaik dalam peramalan pertamax.

Model fungsi transfer merupakan salah satu model peramalan kuantitatif yang dapat digunakan untuk peramalan data deret berkala yang multivariat. Model fungsi transfer multivariat yaitu model fungsi transfer yang memiliki lebih dari satu variabel bebas. Fungsi transfer adalah menggabungkan karakteristik dari model-model ARIMA yang univariat dan beberapa karakteristik

analisis regresi berganda. Fungsi transfer menggabungkan pendekatan deret berkala dengan sebab dan akibat.

Berdasarkan pemaparan isu di atas perlu dilakukan penelitian untuk meramalkan produktivitas lima buah (apel, jeruk siam/keprok, alpukat, jambu biji, dan pisang) yang dipengaruhi suhu, curah hujan, dan kelembaban di Kota Batu periode Januari 2008 sampai Desember 2018 dengan metode ARIMA, *Feedforward Neural Network* (FFNN), dan Fungsi Transfer. Dimana ketiga metode tersebut akan dibandingkan untuk menemukan model terbaik dalam meramalkan produksi lima buah di Kota Batu periode mendatang.

## **1.2 Rumusan Masalah**

Produksi apel di Kota Batu mengalami penurunan sejak tahun 2014. Namun penurunan produksi apel diikuti oleh meningkatnya produksi buah lain seperti jeruk siam/keprok, alpukat, jambu biji, dan pisang. Penurunan produksi apel tersebut diduga akibat berubahnya iklim. Petani apel juga menilai bahwa penurunan panen apel akhir-akhir ini disebabkan karena perubahan iklim dan hujan yang terus menerus. Seiring dengan penurunan produksi apel, tanaman lain yang banyak diusahakan antara lain jeruk siam/keprok, alpukat, jambu biji, dan pisang produksinya mengalami kenaikan. Berdasarkan pemaparan isu di atas perlu dilakukan penelitian dengan perumusan masalah sebagai berikut.

1. Bagaimana karakteristik curah hujan, suhu udara, kelembaban, dan produktivitas lima buah di Kota Batu periode Januari 2008 sampai Desember 2018?
2. Bagaimana model terbaik untuk meramalkan produktivitas lima buah yang dipengaruhi suhu, curah hujan, dan kelembaban di Kota Batu periode Januari 2008 sampai Desember 2018?
3. Bagaimana hasil peramalan produktivitas lima buah pada periode Januari sampai Desember 2019?

### **1.3 Tujuan**

Berdasarkan perumusan masalah di atas, maka tujuan dari penelitian ini adalah sebagai berikut.

1. Mendapatkan hasil karakteristik curah hujan, suhu udara, kelembaban, dan produktivitas lima buah di Kota Batu periode Januari 2008 sampai Desember 2018.
2. Memperoleh model terbaik untuk meramalkan produktivitas lima buah yang dipengaruhi suhu, curah hujan, dan kelembaban di Kota Batu periode Januari 2008 sampai Desember 2018.
3. Memperoleh hasil peramalan produktivitas apel pada periode Januari sampai Desember 2019.

### **1.4 Ruang Lingkup / Batasan Masalah**

Batasan masalah pada penelitian ini adalah variabel yang digunakan yaitu produktivitas lima buah yang ada di Kota Batu yaitu apel, jeruk siam/keprok, alpukat, jambu biji, pisang, dan variabel suhu udara, curah hujan, dan kelembaban di Kota Batu periode bulan Januari 2008 sampai Desember 2018.

### **1.5 Manfaat Penelitian**

Manfaat yang diperoleh pada penelitian ini adalah dapat memberikan gambaran informasi terhadap pihak terkait mengenai peramalan produktivitas lima buah di Kota Batu yang dipengaruhi oleh suhu, curah hujan, dan kelembaban, sehingga dapat dilakukan pengambilan kebijakan dengan tepat untuk meningkatkan produksi lima buah tersebut di periode mendatang. Manfaat bagi peneliti dapat mempelajari model statistik dengan Fungsi Transfer dan model *Machine Learning* dengan FFNN.

## **BAB II**

### **TINJAUAN PUSTAKA**

Tinjauan pustaka ini membahas mengenai metode yang digunakan diantaranya *Time Series Analysis*, Model ARIMA, Model Fungsi Transfer, Uji *White* sebagai pengujian linieritas pada data, *Feedforward Neural Network* (FFNN), dan Pemilihan Model Terbaik. Ada pula beberapa tinjauan pustaka yang berkaitan dengan penelitian ini yaitu pengertian suhu, curah hujan, kelembaban, dan produktivitas buah.

#### **2.1 *Time Series Analysis***

*Time Series* merupakan urutan observasi yang berdasarkan pada interval waktu yang sama, sehingga terdapat korelasi antara kejadian saat ini dengan satu periode sebelumnya. Penerapan metode *time series* dalam berbagai bidang diantaranya bidang ekonomi, bisnis, pertanian, kesehatan, teknik, meteorologi, *quality control*, dan penelitian sosial (Wei, 2006). Tujuan dari analisis *time series* adalah untuk memodelkan suatu proses stokastik dari suatu deret yang diamati dan untuk memprediksi atau meramalkan nilai masa depan berdasarkan kejadian sebelumnya maupun faktor-faktor yang berpengaruh terhadap data.

#### **2.2 *Autoregressive Integrated Moving Average* (ARIMA)**

Model ARIMA adalah kombinasi model *Autoregressive* (AR) orde  $p$  dan *Moving average* (MA) orde  $q$ , dan proses *differencing* dengan orde  $d$  (Wei, 2006). Model ARIMA *Box-Jenkins* dapat dibagi ke dalam kelompok yaitu model *Autoregressive* (AR), *Moving Average* (MA), dan metode campuran *Autoregressive Moving Average* (ARMA) sebagai berikut:

##### **1. *Autoregressive* Model (AR)**

Model *Autoregressive* secara umum untuk proses AR order ke- $p$  atau model ARIMA  $(p,0,0)$  dinyatakan sebagai berikut:

$$\dot{Y}_t = \phi_1 \dot{Y}_{t-1} + \dots + \phi_p \dot{Y}_{t-p} + a_t \quad (2.1)$$

dengan

$$\dot{Y}_t = Y_t - \mu$$

$\phi_p$  : parameter *autoregressive* ke-p.

## 2. *Moving Average Model (MA)*

Model *moving average* secara umum proses MA orde ke-q atau ARIMA (0,0,q) dinyatakan sebagai berikut:

$$\dot{Y}_t = a_1 - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.2)$$

dengan

$$\dot{Y}_t = Y_t - \mu$$

$\theta_q$  : parameter *moving average*.

## 3. *Model Autoregressive Moving Average (ARMA)*

Model ARMA secara umum untuk campuran proses AR (p) murni dan MA (q) murni, yaitu ARIMA (p,0,q) dapat dinyatakan dengan rumus sebagai berikut:

$$\phi_p(B) \dot{Y}_t = \theta_q(B) a_t \quad (2.3)$$

dengan

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q.$$

## 4. *Model Autoregressive Integrated Moving Average*

Apabila data tidak stationer maka komponen yang tidak stationer tersebut ditambahkan pada campuran proses ARMA, sehingga model ARIMA (p,d,q). Secara umum model ARIMA (p,d,q) dapat dinyatakan sebagai berikut:

$$\phi_p(B)(1-B)^d Y_t = \theta_q(B) a_t \quad (2.4)$$

dengan

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

$(1-B)^d$  = operator *differencing* untuk orde  $d$ ,

$a_t$  = *error* pada waktu ke- $t$ .

### 5. Model ARIMA musiman

Model ARIMA musiman yang mempunyai efek musiman dalam pengamatan waktu ke- $t$  dinotasikan dengan ARIMA (P,D,Q)<sup>S</sup>. Secara umum model ARIMA musiman dapat dituliskan dalam rumus sebagai berikut:

$$\Phi_P(B^S)(1-B^S)^D Y_t = \Theta_Q(B^S)a_t \quad (2.5)$$

dengan

S adalah periode musiman

$$\Phi_P(B) = 1 - \Phi_1 B^S - \dots - \Phi_P B^{PS}$$

$$\Theta_Q(B) = 1 - \Theta_1 B^S - \dots - \Theta_Q B^{QS}$$

### 6. Proses ARIMA Multiplikatif

Model ARIMA dengan data multiplikatif dapat dinotasikan dengan ARIMA (p,d,q)(P,D,Q)<sup>S</sup>. Secara umum model ARIMA multiplikatif dapat dituliskan dalam rumus sebagai berikut:

$$\Phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^D Y_t = \theta_q(B)\Theta_Q(B^S)a_t. \quad (2.6)$$

## 2.3 Model Fungsi Transfer

Model fungsi transfer adalah suatu model yang menggambarkan nilai prediksi masa depan dari suatu *time series* didasarkan pada nilai-nilai masa lalu itu sendiri dan satu atau lebih variabel yang berhubungan dengan *output series* tersebut (Wei, 2006). Bentuk umum persamaan model fungsi transfer *single input* ( $X_t$ ) dengan *single output* adalah:

$$Y_t = v(B)X_t + \eta_t \quad (2.7)$$

dimana  $Y_t$  adalah deret *output* yang stationer,  $X_t$  adalah deret *input* yang stationer, dan  $\eta_t$  adalah deret *noise*, dengan:

$$v(B) = \frac{\omega_S(B)B^b}{\delta_r(B)} \quad \text{dan} \quad \eta_t = \frac{\theta(B)}{\phi(B)}a_t$$

Sehingga persamaan (2.7) menjadi persamaan (2.8).

$$Y_t = \frac{\omega_s(B)B^b}{\delta_r(B)} X_t + \frac{\theta(B)}{\phi(B)} a_t \quad (2.8)$$

dengan

$$\omega_s(B) = \omega_0 - \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s$$

$$\delta_r(B) = 1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r$$

Berikut merupakan tahapan-tahapan yang dilakukan dalam analisis fungsi transfer:

### Tahap 1 : Identifikasi Model Fungsi Transfer

1. Mempersiapkan deret *input* ( $X_t$ ) dan *output* ( $Y_t$ ) yang telah stationer.
2. Menentukan model ARMA untuk deret *input* ( $X_t$ )

$$\phi_x(B)X_t = \theta_x(B)\alpha_t \quad (2.9)$$

3. *Prewhitening* deret *input* ( $X_t$ )

$$\alpha_t = \frac{\phi_x(B)}{\theta_x(B)} X_t \quad (2.10)$$

4. *Prewhitening* deret *output* ( $Y_t$ )

$$\beta_t = \frac{\phi_x(B)}{\theta_x(B)} Y_t \quad (2.11)$$

5. Mendeteksi dan mengukur hubungan kekuatan antara  $\alpha_t$  dengan  $\beta_t$  dengan menggunakan CFC (*Cross Correlation Function*).

$$\gamma_{xy}(k) = E[(X_t - \mu_x)(Y_{t+k} - \mu_y)] \quad (2.12)$$

$$\rho_{xy}(k) = \frac{\gamma_{xy}(k)}{\sigma_x \sigma_y} \quad (2.13)$$

6. Menetapkan nilai ( $b, r, s$ ) yang menghubungkan deret *input* dan deret *output*.
  - a. Nilai  $b$  menyatakan bahwa  $Y_t$  tidak dipengaruhi oleh nilai  $X_t$  sampai periode  $t+b$ , besarnya  $b$  adalah log bobot respon impuls yang pertama tidak berbeda dari nol.

- b. Nilai  $s$  menyatakan bahwa berapa lama deret *output* ( $Y_t$ ) secara terus-menerus dipengaruhi oleh nilai-nilai baru deret *input* ( $X_t$ ).
  - c. Nilai  $r$  menunjukkan bahwa  $Y_t$  berkaitan dengan nilai-nilai masa lalunya.  $r=0$  bila jumlah bobot respon impuls hanya terdiri dari beberapa lag yang kemudian terpotong,  $r=1$  bila bobot respon impuls menunjukkan suatu pola eksponensial menurun, dan  $r=2$  bila bobot respon impuls menunjukkan suatu pola eksponensial menurun dan pola sinusoidal.
7. Penaksiran awal deret *noise* ( $\hat{\eta}_t$ )
  8. Penentuan model deret *noise* ARMA ( $p_n, q_n$ )

## Tahap 2 : Estimasi Parameter Model Fungsi Transfer

Penaksiran parameter-parameter fungsi transfer dapat menggunakan metode estimasi seperti model ARIMA *univariate*. Salah satunya, apabila residual memenuhi asumsi *white noise* dan  $N(0, \hat{\sigma}_\alpha^2)$  dapat menggunakan metode *conditional maximum likelihood* untuk mengestimasi parameter  $\delta, \omega, \phi, \theta$  dengan fungsi *likelihood* (Wei, 2006).

## Tahap 3 : Pengujian Signifikansi Parameter Model Fungsi Transfer

Hipotesis yang digunakan untuk pengujian signifikansi parameter dalam model adalah sebagai berikut:

$$H_0 : \tau_i = 0 \text{ (parameter model tidak signifikan)}$$

$$H_1 : \tau_i \neq 0 \text{ (parameter model signifikan)}$$

$$\text{Statistik uji : } t = \frac{\hat{\tau}_i}{stdev(\hat{\tau}_i)} \quad (2.14)$$

dimana  $\hat{\tau}_i$  merupakan parameter  $\delta_i, \omega_i, \phi_i, \theta_i$ .

Tolak  $H_0$  jika  $|t_{hitung}| > t_{\alpha/2(n-M)}$  atau  $p\text{-value} < \alpha$  yang artinya bahwa parameter model signifikan, dimana  $n$  menunjukkan jumlah data dan  $M$  adalah jumlah parameter yang ditaksir (Wei, 2006).

#### Tahap 4 : Uji Kesesuaian Model Fungsi Transfer

Model fungsi transfer sementara yang telah didapatkan untuk selanjutnya di uji kesesuaian modelnya. Adapun langkah-langkah dalam uji kesesuaian model fungsi transfer adalah sebagai berikut (Wei, 2006):

1. Pengujian *cross correlation* antara residual model deret *noise* dan deret *input* yang telah mengalami *prewhitening*, tujuannya untuk mengetahui bahwa kedua deret tersebut bersifat independen. Model yang sesuai adalah model yang CCF antara residual model deret *noise* dan deret *input* tidak menunjukkan pola tertentu dan terletak di antara  $2(n-k)^{-1/2}$ .
2. Pengujian autokorelasi residual model deret *noise* yang menghubungkan deret *input* dan *output* atau disebut juga uji *white noise* menggunakan statistik uji *Ljung-Box*.

#### Tahap 5 : Penggunaan Model Fungsi Transfer

Setelah model fungsi transfer diperoleh, maka selanjutnya ditentukan model terbaik apabila terdapat beberapa model alternatif. Model terbaik dipilih berdasarkan kriteria *Root Mean Square Error Prediction* (RMSEP) dan *Mean Absolute Percentage Error Prediction* (MAPEP) (Wei, 2006).

#### 2.4 Pengujian Linieritas

Pengujian linieritas yang digunakan dalam penelitian ini yaitu Uji *White*. Uji *White* merupakan uji deteksi non-linieritas yang dikembangkan dari model *neural network* yang ditemukan oleh White pada tahun 1989. Model yang digunakan pada Uji *White* adalah sebagai berikut:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \theta_1 X_{1t}^* + \theta_2 X_{2t}^* + a_t \quad (2.15)$$

dengan  $X_{1t}^*$  dan  $X_{2t}^*$  merupakan komponen nonlinier pada uji *White* yang diturunkan dari model *neural network*. Hipotesis dari Uji *White* sebagai berikut (Lee, White, & Granger, 1993):

$H_0 : \theta_1 = \theta_2 = 0$  (hubungan linear)

$H_1 : \text{minimal ada satu } \theta_i \neq 0, \text{ dengan } i = 1, 2$  (hubungan tidak linier)

Berikut merupakan langkah-langkah pengujian *White*:

1. Meregresikan  $Y_t$  dengan  $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  dan menghitung *residual*  $\hat{u}_t$  dan menghitung *sum square residual*

$$SSR_0 = \sum_{t=1}^n \hat{u}_t^2 .$$

2. Meregresikan  $\hat{u}_t$  pada  $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  dan prediktor tambahan yaitu  $X_{1t}^*$  dan  $X_{2t}^*$  serta menghitung residual  $\hat{v}_t$  dan

$$\text{sum square residual } SSR_1 = \sum_{t=1}^n \hat{v}_t^2 .$$

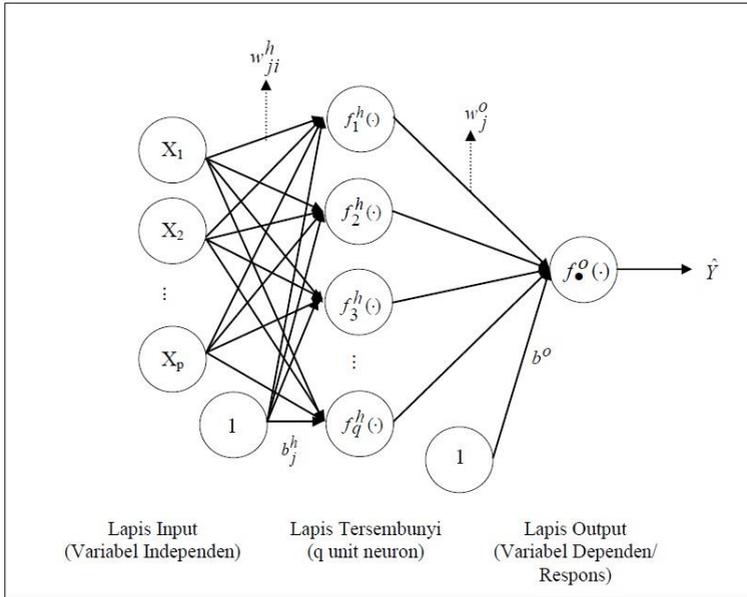
3. Menghitung  $F_{hitung} = \frac{(SSR_0 - SSR_1) / 2}{SSR_1 / (n - p - 1 - 2)}$ , dengan  $n$  adalah jumlah pengamatan yang digunakan.

Nilai uji F ini mendekati distribusi F dengan derajat bebas 2 dan  $(n-p-1-2)$ .

## 2.5 Feedforward Neural Network (FFNN)

Pemodelan regresi, runtun waktu, dan *signal processing* adalah salah satu aplikasi *Neural Network* yang biasanya berdasarkan pada arsitektur FFNN. Dalam pemodelan statistik, FFNN dapat dipandang sebagai suatu kelas yang fleksibel dari fungsi-fungsi nonlinier. Secara umum, model ini bekerja dengan menerima suatu vektor dari input  $x$  dan kemudian menghitung suatu respon atau output  $\hat{Y}(x)$  dengan memproses (propagating)  $x$  melalui elemen-elemen proses yang saling terkait. Elemen-elemen proses tersusun dalam beberapa *layer* dan data input,  $x$ , mengalir dari satu *layer* ke *layer* berikutnya secara berurutan. Dalam tiap-tiap *layer*, input-input ditransformasikan kedalam *layer* secara nonlinear oleh elemen-elemen proses dan kemudian

diproses maju ke *layer* berikutnya. Akhirnya, nilai-nilai output  $\hat{Y}$ , yang dapat berupa nilai-nilai skalar atau vektor, dihitung pada *output layer* (Suhartono, 2007).



**Gambar 2.1** Arsitektur FFNN dengan satu *hidden layer*,  $p$  unit input,  $q$  unit neuron di *hidden layer*, dan satu unit neuron output.

Gambar 2.1 adalah suatu contoh dari bentuk khusus FFNN dengan satu *hidden layer* yang lebih dikenal dengan FFNN satu *hidden layer* yang terdiri dari  $q$  unit neuron dan arsitektur ini, nilai-nilai respon atau output  $\hat{Y}$  dihitung dengan rumus sebagai berikut:

$$\hat{Y}_{(k)} = f^o \left[ \sum_{j=1}^q w_j^o f_j^h \left( \sum_{i=1}^p w_{ji}^h X_{i(k)} + b_j^h \right) + b^o \right] \quad (2.16)$$

dengan

$X_{i(k)}$  = variabel input sebanyak  $p$ , ( $i = 1, 2, \dots, p$ )

- $\hat{Y}_{(k)}$  = nilai dugaan dari variabel output
- $k$  = indeks pasangan data input-target  
( $X_{i(k)}, Y_{(k)}$ ),  $k = 1, 2, \dots, n$
- $w_{ji}^h$  = bobot dari input ke- $i$  yang menuju neuron ke- $j$  pada  
*hidden layer*, dengan  $j = 1, 2, \dots, q$
- $b_j^h$  = bias pada neuron ke- $j$  pada *hidden layer*,  
dengan  $j = 1, 2, \dots, q$
- $f_j^h$  = fungsi aktivasi di neuron ke- $j$  pada *hidden layer*
- $w_j^o$  = bobot dari neuron ke- $j$  di *hidden layer* yang menuju  
neuron pada *output layer*
- $b^o$  = bias pada neuron di *output layer*
- $f^o$  = fungsi aktifasi pada neuron di lapis output.

Bentuk nonlinier fungsi  $\hat{Y}$  terjadi melalui suatu fungsi yang disebut fungsi aktivasi  $f_j^h$  pada *hidden layer* dan  $f^o$  pada *output layer*, biasanya fungsi halus atau *smooth* seperti fungsi logistik sigmoid. Beberapa notasi akan digunakan untuk memperjelas penjabaran proses input-output FFNN pada Gambar 2.1. *Superscript "h"* digunakan sebagai indeks yang menyatakan *hidden layer* dan "o" untuk indeks yang menyatakan *output layer*. Digunakan juga  $v_j^h$  untuk menyatakan suatu vektor nilai-nilai setelah proses penjumlahan input dan bobot-bobot (bias termasuk di dalamnya) pada *hidden layer* neuron ke- $j$ , yaitu pada persamaan (2.17) (Suhartono, 2007).

$$v_j^h = \sum_{i=1}^p w_{ji}^h x_i + b_j^h \quad (2.17)$$

atau untuk data ke  $k$  diperoleh:

$$v_{j(k)}^h = \sum_{i=1}^p w_{ji}^h x_{i(k)} + b_j^h \quad (2.18)$$

*Output* pada *hidden layer* yang terproses di neuron ke- $j$  adalah sebagai berikut:

$$a_j^h = f_j^h(v_j^h) \quad (2.19)$$

atau untuk data ke  $k$  diperoleh:

$$a_{j(k)}^h = f_j^h(v_{j(k)}^h) = f_j^h\left(\sum_{i=1}^p w_{ji}^h x_{i(k)} + b_j^h\right) \quad (2.20)$$

Dengan cara yang sama, maka beberapa notasi yang menyatakan penjumlahan input dan bobot-bobot pada *output layer* adalah sebagai berikut:

$$v^o = \sum_{j=1}^q w_j^o a_j^h + b^o \quad (2.21)$$

atau untuk data ke  $k$  diperoleh:

$$v_{(k)}^o = \sum_{j=1}^q w_j^o a_{j(k)}^h + b^o \quad (2.22)$$

Output pada *output layer* adalah sebagai berikut:

$$\hat{Y}_{(k)} = a_{(k)}^o = f^o(v_{(k)}^o) \quad (2.23)$$

Dengan demikian, hubungan antara input  $X_{i(k)}$ ,  $i = 1, 2, \dots, p$  dan  $k = 1, 2, \dots, n$ , dengan output  $Y_{(k)}$  adalah sebagai berikut:

$$\begin{aligned} \hat{Y}_{(k)} &= f^o\left(\sum_{j=1}^q w_j^o f_j^h(v_{j(k)}^h) + b^o\right) \\ \hat{Y}_{(k)} &= f^o\left[\sum_{j=1}^q w_j^o f_j^h\left(\sum_{i=1}^p w_{ji}^h X_{i(k)} + b_j^h\right) + b^o\right] \\ \hat{Y}_{(k)} &= F(x_{1(k)}, x_{2(k)}, \dots, x_{p(k)}) \end{aligned} \quad (2.24)$$

Pemetaan secara keseluruhan yang terjadi pada FFNN ini selanjutnya dapat ditulis dalam bentuk sebagai berikut:

$$\begin{bmatrix} \hat{Y}_{(1)} \\ \hat{Y}_{(2)} \\ \vdots \\ \hat{Y}_{(n)} \end{bmatrix} = \begin{bmatrix} F(x_{1(1)}, x_{2(1)}, \dots, x_{p(1)}) \\ F(x_{1(2)}, x_{2(2)}, \dots, x_{p(2)}) \\ \vdots \\ F(x_{1(n)}, x_{2(n)}, \dots, x_{p(n)}) \end{bmatrix} \quad (2.25)$$

Penurunan dan pembuktian algoritma *backpropagation* pada FFNN yang banyak digunakan untuk analisis runtun waktu dan regresi yaitu dengan melakukan *fitting* terhadap parameter-parameter fungsi dengan metode *least square*. Misalkan beberapa pasang sampel input dan target  $(X_{i(k)}, Y_{(k)})$ , dan output dari *networks* adalah  $\hat{Y} = f(\mathbf{x}, \mathbf{w})$ . Maka, vektor parameter  $w$  dipilih dengan cara meminimumkan sebagai berikut:

$$Q(\mathbf{w}) = \sum_{k=1}^n \left[ Y_{(k)} - f(X_{(k)}, \mathbf{w}) \right]^2 \quad (2.26)$$

seperti yang dilakukan dalam regresi nonlinear.

Secara umum, aplikasi *nonlinear least square* pada *neural networks* terbagi dalam dua pendekatan untuk mengupdate bobot-bobot, yaitu yang dikenal dengan adaptasi *offline* dan *online*. Pada adaptasi *offline*, bobot-bobot diupdate pada setiap pasangan input-output, sedangkan adaptasi *online* atau yang dikenal dengan *batch mode*, bobot-bobot hanya diupdate setelah pasangan data input-output pada data training terproses. Bagian ini hanya menjelaskan aplikasi dari algoritma *nonlinear least squares* pada training yang diproses secara *batch mode* dari suatu FFNN.

*Gradient descent* merupakan salah satu dari kelompok metode optimasi yang paling tua, metode ini berdasarkan pada suatu pendekatan linear dari fungsi kesalahan (*error*) yaitu:

$$Q(\mathbf{w} + \Delta \mathbf{w}) \approx Q(\mathbf{w}) + \Delta \mathbf{w}^T Q'(\mathbf{w}) \quad (2.27)$$

bobot-bobot diupdate melalui

$$\Delta \mathbf{w} = -\eta Q'(\mathbf{w}), \eta > 0 \quad (2.28)$$

dengan  $\eta$  adalah suatu koefisien pembelajaran (*learning rate*).

Berikut adalah formula untuk mendapatkan bobot-bobot pada model FFNN yang digunakan untuk peramalan runtun

waktu univariat seperti pada Gambar 2.1 dengan menggunakan metode *gradient descent*. Dua persamaan *update* untuk bobot  $w_{ji}^h$ ,  $b_j^h$ ,  $w_j^o$ , dan  $b^o$  akan diberikan secara terpisah sebagai berikut:

a. Untuk *updating* bobot-bobot dan bias pada lapis output

$$w_j^{o(m+1)} = w_j^{o(m)} + \eta \sum_{k=1}^n \delta_j^{o(m)} a_{j(k)}^{h(m)} \quad (2.29)$$

$$b^{o(m+1)} = b^{o(m)} + \eta \sum_{k=1}^n \delta_j^{o(m)} \quad (2.30)$$

b. Untuk *updating* bobot-bobot dan bias pada lapis tersembunyi

$$w_{ji}^{h(m+1)} = w_{ji}^{h(m)} + \eta \sum_{k=1}^n \delta_j^{h(m)} x_{i(k)} \quad (2.31)$$

$$b_j^{h(m+1)} = b_j^{h(m)} + \eta \sum_{k=1}^n \delta_j^{h(m)} \quad (2.32)$$

dengan  $\eta$  adalah koefisien pembelajaran (*learning rate*) dan  $m$  merupakan iterasi.

## 2.6 Pemilihan Model Terbaik

Pemilihan model terbaik pada penelitian ini menggunakan kriteria kesalahan peramalan untuk data *out sample* menggunakan *Root Mean Square Error Prediction* (RMSEP) dan *Mean Absolute Percentage Error Prediction* (MAPEP). RMSEP merupakan kriteria pemilihan model terbaik berdasarkan pada hasil sisa ramalannya dan digunakan untuk segala satuan data. Berikut merupakan rumus RMSEP (Chen & Yang, 2004):

$$RMSEP = \sqrt{\frac{1}{L} \sum_{l=1}^L (Y_{n+l} - \hat{Y}_n(l))^2} \quad (2.33)$$

MAPEP digunakan untuk mengetahui rata-rata harga mutlak dari persentase kesalahan tiap model. Rumus MAPEP adalah sebagai berikut (Chen & Yang, 2004):

$$MAPEP = \frac{1}{L} \sum_{l=1}^L \left| \frac{Y_{n+l} - \hat{Y}_n(l)}{Y_{n+l}} \right| \times 100\% \quad (2.34)$$

dengan

$Y_{n+l}$  = data *out sample*

$\hat{Y}_n(l)$  = nilai ramalan

$n$  = jumlah data *in sample*

$L$  = jumlah data *out sample*.

## 2.7 Tinjauan Non Statistik

Tinjauan non statistik pada penelitian ini ada beberapa istilah yang digunakan yaitu suhu udara, curah hujan, kelembaban, dan produktivitas buah. Suhu udara adalah derajat panas dan dingin udara di atmosfer. Suhu udara di permukaan tergantung pada faktor-faktor yang mempengaruhinya misalnya lama penyinaran matahari. Suhu udara bervariasi menurut tempat dan waktu yang ada di permukaan bumi (Ahmad, 2018). Selanjutnya, curah hujan merupakan ketinggian air hujan yang terkumpul dalam tempat yang datar, tidak meresap, dan tidak mengalir. Satuan curah hujan di Indonesia dinyatakan dalam milimeter (mm). Curah hujan dalam 1 mm memiliki arti dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi 1 mm atau tertampung air sebanyak 1 liter. Sedangkan kelembaban adalah tingkat kebasahan udara atau konsentrasi uap air di udara. Kandungan uap air pada udara hangat lebih banyak daripada kandungan uap air pada udara dingin. Angka kelembaban dapat digambarkan dalam kelembaban absolut dan kelembaban spesifik atau relatif. Kelembaban absolut banyaknya uap air dalam gram pada  $1m^3$ . Sedangkan kelembaban relatif adalah perbandingan antara kelembaban absolut dengan kapasitas udara untuk menampung air pada suhu yang sama. Selanjutnya, produktivitas merupakan istilah dalam kegiatan produksi sebagai perbandingan antara luaran (*output*) dengan masukan (*input*). Sedangkan produktivitas buah adalah perbandingan antara hasil produksi (kg) dengan jumlah pohon, sehingga satuannya menjadi (kg/pohon).

*Halaman ini sengaja dikosongkan*

## BAB III METODOLOGI PENELITIAN

### 3.1 Sumber Data dan Variabel Penelitian

Sumber data pada penelitian ini adalah data sekunder yang diambil dari Dinas Pertanian Kota Batu, BPS Kota Batu, dan BMKG Karangploso Malang. Data yang diambil dari Dinas Pertanian Kota Batu adalah data jumlah produksi jumlah pohon dari buah yang ada di Kota Batu periode Januari 2008 sampai Desember 2018, kemudian akan dilakukan perhitungan produktivitas dengan cara membandingkan antara banyaknya produksi buah dengan jumlah pohon. Data suhu, curah hujan, dan kelembaban di Kota Batu periode Januari 2008 sampai Desember 2018 diambil dari Kota Batu Dalam Angka yang kemudian dilengkapi dari BMKG Karangploso Malang. Data yang digunakan merupakan data triwulanan. Data dibagi menjadi data training dan data testing, dimana data training pada periode triwulan I tahun 2008 sampai triwulan IV tahun 2017. Sedangkan data testing pada periode triwulan I tahun 2018 sampai triwulan IV tahun 2018.

### 3.2 Variabel Penelitian

Variabel penelitian yang digunakan dapat dilihat pada Tabel 3.1.

**Tabel 3.1** Variabel Penelitian

Variabel	Satuan	Keterangan
Produktivitas Apel	Kg/pohon	Variabel Dependen
Produktivitas Jeruk siam/keprok	Kg/pohon	
Produktivitas Alpukat	Kg/pohon	
Produktivitas Jambu biji	Kg/pohon	
Produktivitas Pisang	Kg/pohon	
Suhu Udara	°C	Variabel Independen
Curah Hujan	mm	
Kelembaban	%	

Struktur data yang digunakan pada penelitian ini adalah sebagai berikut.

**Tabel 3.2** Struktur Data

Tahun	Triwulan	$Y_{1,t}$	$Y_{2,t}$	$Y_{3,t}$	$Y_{4,t}$	$Y_{5,t}$	$X_{1,t}$	$X_{2,t}$	$X_{3,t}$
2008	Triwulan I	$Y_{1,1}$	$Y_{2,1}$	$Y_{3,1}$	$Y_{4,1}$	$Y_{5,1}$	$X_{1,1}$	$X_{2,1}$	$X_{3,1}$
2008	Triwulan II	$Y_{1,2}$	$Y_{2,2}$	$Y_{3,2}$	$Y_{4,2}$	$Y_{5,2}$	$X_{1,2}$	$X_{2,2}$	$X_{3,2}$
2008	Triwulan III	$Y_{1,3}$	$Y_{2,3}$	$Y_{3,3}$	$Y_{4,3}$	$Y_{5,3}$	$X_{1,3}$	$X_{2,3}$	$X_{3,3}$
2008	Triwulan IV	$Y_{1,4}$	$Y_{2,4}$	$Y_{3,4}$	$Y_{4,4}$	$Y_{5,4}$	$X_{1,4}$	$X_{2,4}$	$X_{3,4}$
2009	Triwulan I	$Y_{1,5}$	$Y_{2,5}$	$Y_{3,5}$	$Y_{4,5}$	$Y_{5,5}$	$X_{1,5}$	$X_{2,5}$	$X_{3,5}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2018	Triwulan IV	$Y_{1,44}$	$Y_{2,44}$	$Y_{3,44}$	$Y_{4,44}$	$Y_{5,44}$	$X_{1,44}$	$X_{2,44}$	$X_{3,44}$

### 3.3 Langkah Analisis

Berikut merupakan langkah-langkah analisis yang dilakukan untuk mencapai tujuan dari penelitian.

1. Mendeskripsikan karakteristik produktivitas lima buah, suhu udara, curah hujan, dan kelembaban di Kota Batu.
2. Melakukan pemodelan dengan ARIMA, fungsi transfer, dan FFNN.

Berikut merupakan langkah-langkah yang dilakukan untuk model ARIMA.

- a. Membuat *time series plot*, plot ACF untuk mengetahui apakah data stasioner pada mean, dan plot *Box-Cox* untuk mengetahui apakah data stasioner dalam varians atau tidak.
- b. Jika tidak stasioner maka dilakukan transformasi atau *differencing*.
- c. Melakukan identifikasi dan membuat model dugaan berdasarkan plot ACF dan PACF.

- d. Melakukan penaksiran dan pengujian signifikansi parameter.
- e. Jika signifikan selanjutnya dilakukan uji kebaikan model yaitu uji asumsi *White Noise* dan asumsi berdistribusi normal dengan *Kolmogrov-Smirnov*.
- f. Pemilihan model terbaik dengan menggunakan RMSEP dan MAPEP seperti yang telah dijelaskan pada persamaan (2.33) dan (2.34). Setelah model terpilih, maka peramalan ke depan dilakukan dengan melibatkan semua data.

Berikut merupakan langkah-langkah yang dilakukan untuk analisis fungsi transfer.

- a. Membuat plot *time series* untuk melihat pola yang terbentuk dari keseluruhan data.
- b. Mempersiapkan deret *input* dan *output* untuk mendapatkan deret yang stasioner.
- c. Menentukan model ARIMA untuk deret input seperti persamaan (2.9), serta melakukan *prewhitening* yang dilakukan pada deret *input* dan deret *output* seperti yang telah dijelaskan pada persamaan (2.10) dan (2.11).
- d. Menghitung CCF (*Cross Correlation Function*) untuk deret *input* dan deret *output* setelah dilakukan *prewhitening* seperti yang telah dijelaskan pada persamaan (2.13).
- e. Menaksir secara langsung bobot respon impuls.
- f. Melakukan penaksiran awal deret *noise* dan menentukan  $(p_n, q_n)$  untuk model ARIMA deret *noise*.
- g. Melakukan penaksiran parameter model fungsi transfer dan melakukan pengujian seperti yang telah pada persamaan (2.14).
- h. Melakukan pengujian diagnostik model fungsi transfer.
- i. Menggunakan model fungsi transfer untuk peramalan.
- j. Menghitung tingkat kesalahan peramalan dengan menggunakan RMSEP dan MAPEP seperti yang telah dijelaskan pada persamaan (2.33) dan (2.34).

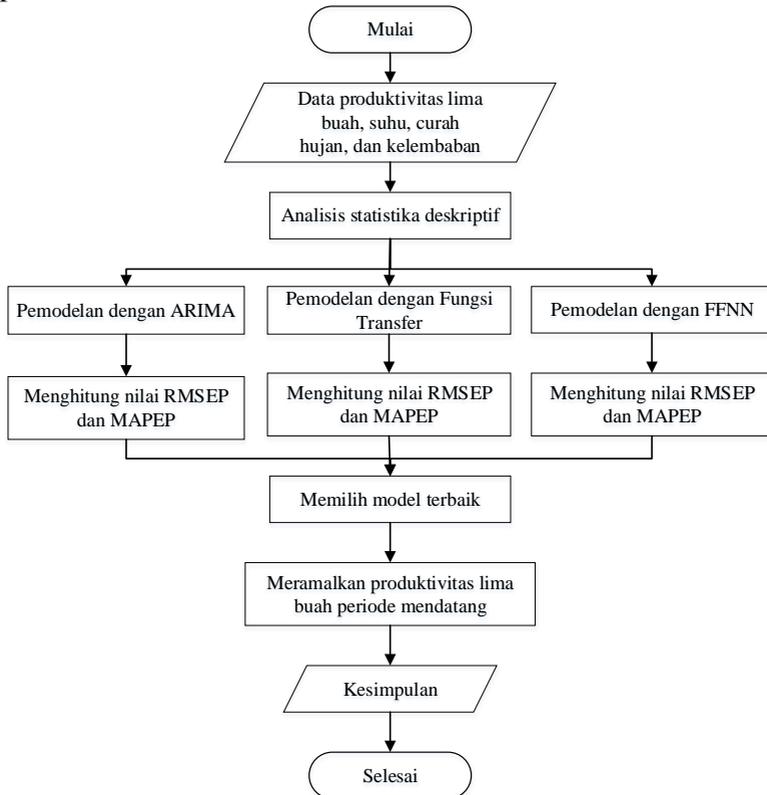
Berikut merupakan langkah-langkah yang dilakukan untuk uji linieritas.

- a. Mempersiapkan variabel respon dan variabel prediktor sesuai dengan hasil dari pemodelan fungsi transfer.
- b. Meregresikan  $Y_t$  dengan  $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  dan menghitung *residual*  $\hat{u}_t$  dan menghitung *sum square residual*  $SSR_0$ .
- c. Meregresikan  $\hat{u}_t$  dengan semua prediktor pada langkah (a) dan  $m$  prediktor tambahan, serta menghitung *residual*  $\hat{v}_t$  sehingga diperoleh *sum square residual*  $SSR_1$ .
- d. Menghitung  $F_{hitung}$  yang telah dijelaskan pada Bab II subbab 2.4.

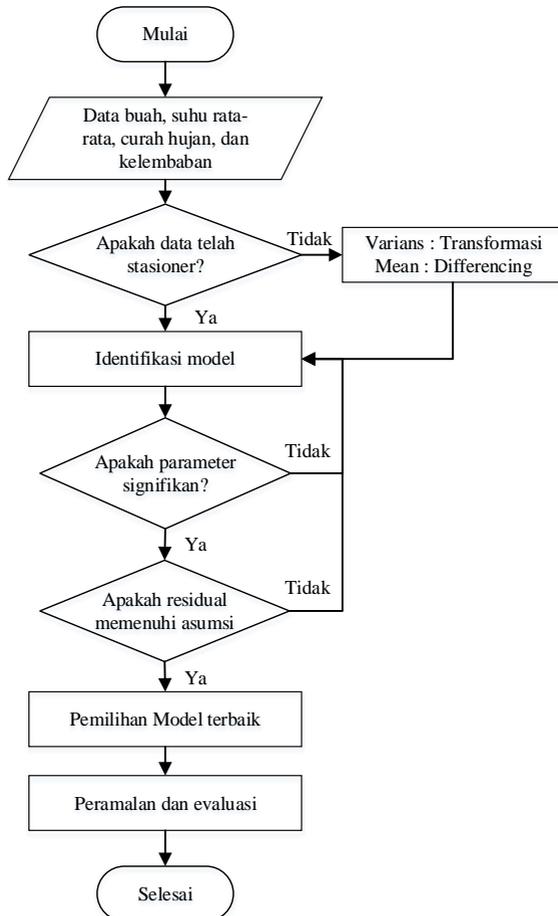
Berikut merupakan langkah-langkah yang dilakukan untuk pemodelan FFNN.

- a. Membagi data menjadi *training* dan *testing*.
  - b. Melakukan *preprocessing* data dengan standarisasi.
  - c. Menentukan *input*, dimana *input* yang digunakan adalah *input* pada model fungsi transfer.
  - d. Memilih jumlah neuron optimum pada setiap *hidden layer* berdasarkan SSE terkecil dengan mencobakan 1 neuron hingga 10 neuron pada setiap *hidden layer*.
  - e. Mendapatkan arsitektur FFNN terbaik beserta *fits* dan *forecast*-nya.
3. Setelah memperoleh ketiga model tersebut maka akan dilakukan perbandingan nilai RMSEP dan MAPEP antara model ARIMA, fungsi transfer, dan FFNN untuk menemukan model terbaik. Selanjutnya meramalkan jumlah produktivitas lima buah periode Januari sampai Desember 2019 dengan menggunakan model terbaik.

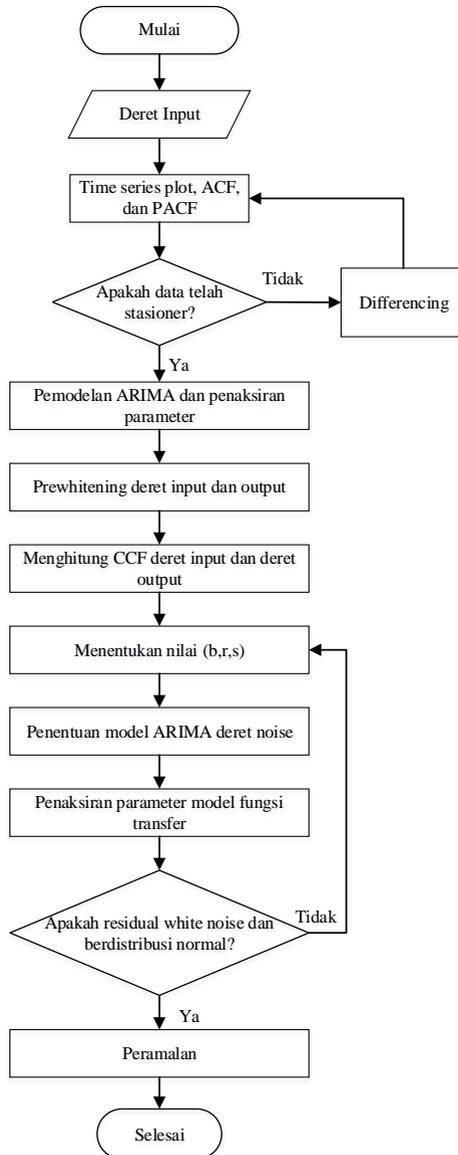
Berikut merupakan gambaran dari langkah analisis pada penelitian ini.



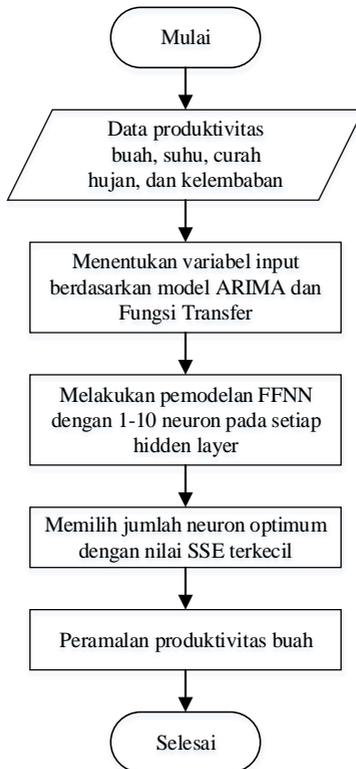
**Gambar 3.1** Diagram Alir Penelitian



**Gambar 3.2** Tahapan Pemodelan ARIMA



**Gambar 3.3** Tahapan Pemodelan Fungsi Transfer



**Gambar 3.4** Tahapan Pemodelan FFNN

## **BAB IV**

### **ANALISIS DAN PEMBAHASAN**

Pada bab ini berisi analisis dan pembahasan mengenai peramalan produktivitas lima buah di Kota Batu. Analisis awal yang dilakukan adalah menggunakan statistika deskriptif berdasarkan grafik garis maupun grafik batang. Selanjutnya dilakukan peramalan menggunakan metode ARIMA, Analisis Fungsi Transfer, dan FFNN. Model terbaik dipilih berdasarkan kriteria kebaikan model *Root Mean Square Error of Prediction* (RMSEP) dan *Mean Absolute Percentage Error of Prediction* (MAPEP). Peramalan berupa produktivitas buah untuk periode 1 tahun ke depan.

#### **4.1 Karakteristik Data Iklim dan Produktivitas Buah di Kota Batu**

Berikut merupakan statistika deskriptif dari suhu udara, kelembaban, curah hujan, dan produktivitas buah yang ada di Kota Batu dapat dilihat pada Tabel 4.1.

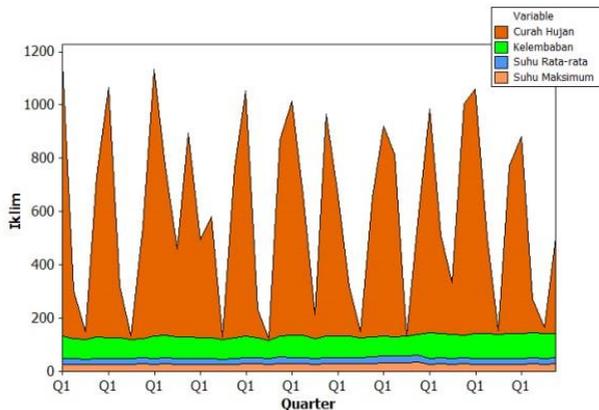
**Tabel 4.1** Karakteristik Data Keseluruhan

Variabel	Rata-rata	Minimum	Maximum
Produktivitas Apel	6,944	0,062	13,12
Produktivitas Jeruk	18,43	2,95	65,95
Produktivitas Alpukat	27,18	2,25	88,91
Produktivitas Jambu Biji	11,4	0,72	29
Produktivitas Pisang	13,11	2,3	78,66
Curah hujan	461,1	0	1026
Suhu	22,79	20,37	27,07
Kelembaban	81,2	68,33	95

Karakteristik data disajikan pada Tabel 4.1 dapat diketahui bahwa rata-rata produktivitas apel paling sedikit dibandingkan buah lainnya, yaitu 7 Kg/pohon tiap triwulan. Produktivitas apel paling sedikit adalah 0,062 Kg/pohon dan

paling banyak adalah 13 Kg/pohon. Rata-rata produktivitas buah paling tinggi adalah buah alpukat, dimana produktivitasnya mencapai 27 Kg/pohon tiap triwulan. Produktivitas alpukat paling sedikit adalah 2 Kg/pohon dan paling banyak adalah 89 Kg/pohon. Suhu rata-rata di Kota Batu adalah 22,79°C, dimana suhu minimum adalah 20,37°C dan suhu maksimum 27,07°C. Sedangkan kelembaban rata-rata adalah 81,2%, dimana kelembaban minimum adalah 68,33% dan kelembaban maksimum adalah 95%. Curah hujan rata-rata tiap triwulan adalah 461,1 mm dengan curah hujan minimum adalah 0 mm, dimana pada periode tersebut tidak terjadi hujan sama sekali. Sedangkan curah hujan maksimum adalah 1026 mm.

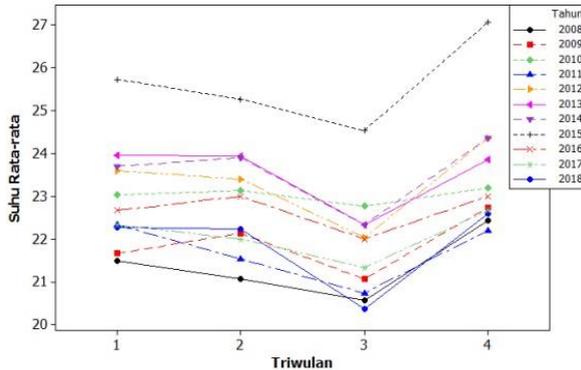
Selanjutnya dilakukan analisis terhadap karakteristik dari suhu udara, kelembaban, dan curah hujan di Kota Batu tahun 2008-2018 dapat dilihat dari grafik pada Gambar 4.1 sebagai berikut.



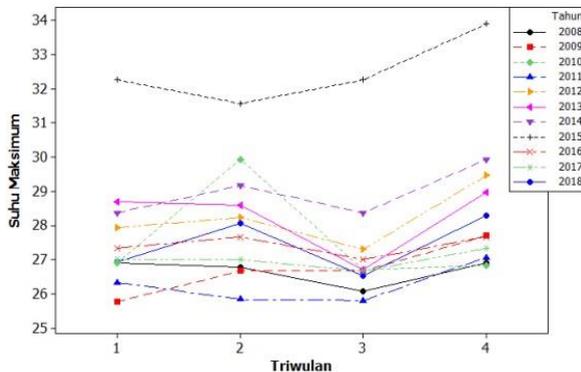
**Gambar 4.1** Karakteristik Suhu Rata-rata, Suhu Maksimum, Kelembaban, dan Curah Hujan di Kota Batu

Karakteristik suhu, curah hujan, dan kelembaban di Kota Batu yang di gambarkan pada Gambar 4.1 menunjukkan bahwa curah hujan memiliki pola fluktuasi dan musiman yang sangat kuat dibandingkan suhu dan kelembaban. Suhu, kelembaban, dan curah hujan di Kota Batu cenderung sama dari tahun ke tahun.

Selanjutnya akan diinformasikan karakteristik suhu, kelembaban, dan curah hujan secara mendalam. Berikut merupakan *line plot* dari suhu rata-rata dan suhu maksimum.



**Gambar 4.2** Karakteristik Suhu Rata-rata tiap Tahun di Kota Batu



**Gambar 4.3** Karakteristik Suhu Maksimum tiap Tahun di Kota Batu

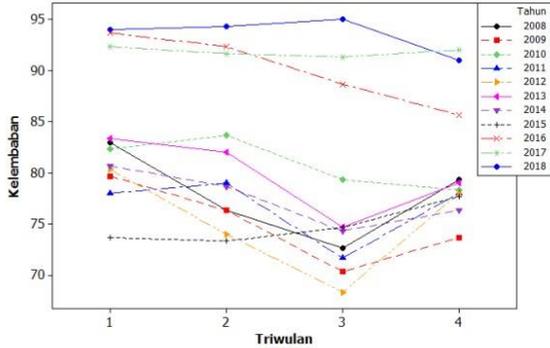
Karakteristik suhu di Kota Batu yang ditunjukkan pada Gambar 4.2 dan Gambar 4.3 dapat dilihat bahwa pola suhu rata-rata dan suhu maksimum hampir sama yaitu berpola musiman, sehingga pada penelitian ini akan digunakan salah satu untuk mempresentasikan suhu di Kota Batu.

Suhu pada triwulan I dan II cenderung sama yaitu pada rentang 21°C -24°C, sedangkan pada triwulan III merupakan suhu terendah yaitu pada rentang 20°C-23°C dan pada triwulan IV merupakan suhu rata-rata tertinggi dari triwulan lainnya yaitu pada rentang 22°C-24°C. Suhu rata-rata di Kota Batu terjadi sedikit penurunan di tahun 2018 yaitu pada rentang 20°C-22°C, dimana suhu tersebut tergolong lebih dingin dibandingkan suhu rata-rata tahun-tahun sebelumnya.

Pada tahun 2015 terjadi peningkatan suhu yang sangat drastis dibandingkan tahun-tahun sebelumnya yaitu pada rentang 32°C-34°C. Hal tersebut terjadi karena adanya fenomena El-Nino yang kuat di tahun tersebut dan mengakibatkan kekeringan panjang di beberapa daerah seperti Sumatera Selatan, Lampung, Jawa, Bali, NTB, NTT dan Sulawesi Selatan. Kekeringan tersebut juga terjadi di berbagai wilayah khususnya di Indonesia yang melanda 16 provinsi meliputi 102 kabupaten/kota dan 721 kecamatan hingga akhir Juli 2015. Lahan pertanian seluas 111 ribu hektar juga mengalami kekeringan. Keadaan tersebut dirasakan mulai parah pada bulan Agustus 2015 hingga September 2015 (Badan Nasional Penanggulangan Bencana, 2015). Terlihat pula pada Gambar 4.2 dimana pada triwulan III seharusnya memiliki suhu paling rendah dibandingkan triwulan yang lain, namun pada tahun 2015 suhu triwulan III lebih tinggi dibandingkan triwulan I dan II. Selanjutnya dilakukan analisis pada karakteristik kelembaban di Kota Batu disajikan pada Gambar 4.4.

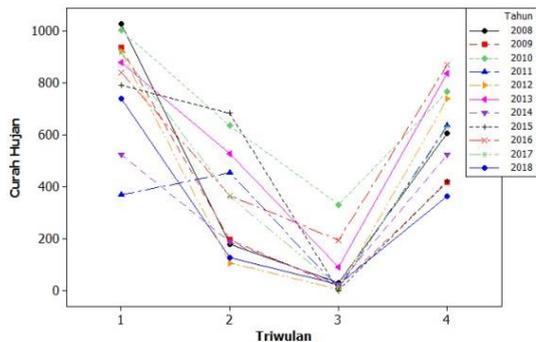
Kelembaban di Kota Batu juga memiliki pola musiman berdasarkan Gambar 4.4, dimana pada triwulan III memiliki kelembaban terendah dibandingkan triwulan lainnya. Sedangkan kelembaban tertinggi terjadi pada triwulan I. Pada tahun 2018, kelembaban di Kota Batu paling tinggi di tahun sebelumnya. Hal tersebut, juga selaras dengan penurunan suhu di tahun yang sama. Dimana sesuai hukum yang ada, apabila kelembaban udara tinggi maka suhu udara akan turun. Sehingga benar bahwa, pada tahun

2018 Kota Batu berada pada kondisi yang sangat dingin dibandingkan tahun-tahun sebelumnya.



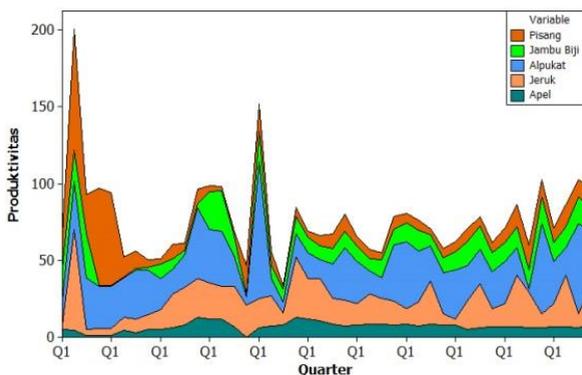
**Gambar 4.4** Karakteristik Kelembaban tiap Tahun di Kota Batu

Pada tahun 2016 dan 2017, kelembaban mulai tinggi dibandingkan tahun-tahun sebelumnya. Sehingga dapat diindikasikan bahwa perubahan kelembaban dimulai pada tahun 2016. Pada tahun 2015 dimana terjadi fenomena El-Nino yang kuat, kelembaban pada triwulan I dan II paling rendah dibandingkan triwulan lainnya. Sedangkan pada triwulan III dan IV lebih tinggi dari triwulan lainnya dalam keadaan normal. Selanjutnya dilakukan analisis karakteristik curah hujan di Kota Batu sebagai berikut.



**Gambar 4.5** Karakteristik Curah Hujan tiap Tahun di Kota Batu

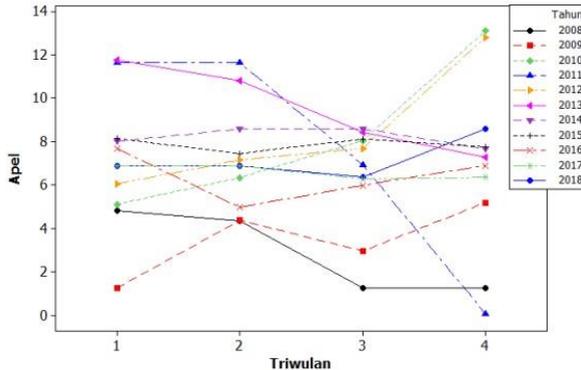
Curah hujan memiliki pola musiman yang sangat kuat yang ditunjukkan pada Gambar 4.5. Curah hujan paling tinggi terjadi triwulan I dan IV, sedangkan curah hujan paling rendah terjadi pada triwulan III. Dimana keadaan tersebut berlaku sama hampir setiap tahun. Kota Batu pernah mengalami situasi dimana curah hujan berturut-turut pada bulan Juli, Agustus, September, Oktober tahun 2015 yaitu 0 mm. Keadaan tersebut berdampak pada kekeriangan. Hal tersebut terjadi karena adanya fenomena El-Nino yang telah dijelaskan pada paragraf sebelumnya. Selanjutnya analisis karakteristik produktivitas lima buah yang ada di Kota Batu. Pada triwulan I tahun 2015, terjadi penurunan curah hujan dibandingkan tahun-tahun lainnya. Hal tersebut juga disebabkan karena adanya fenomena El-Nino yang terjadi secara global.



**Gambar 4.6** Karakteristik Produktivitas Lima Buah di Kota Batu

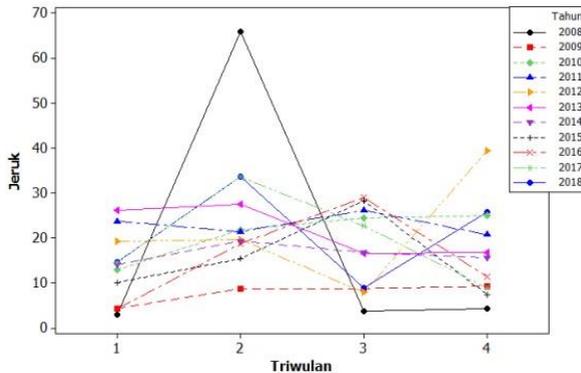
Secara umum produktivitas jeruk, alpukat, jambu biji, dan pisang memiliki pola yang sama dapat dilihat pada Gambar 4.6. Sedangkan apel, memiliki pola produktivitas yang berbeda dari buah lainnya. Produktivitas apel dan jeruk diindikasikan memiliki pola musiman. Walaupun sempat terjadi penurunan produktivitas pada beberapa buah, namun akhi-akhir ini mengalami peningkatan produktivitas buah walaupun tidak signifikan. Selanjutnya akan ditunjukkan karakteristik produktivitas lima

buah di Kota Batu secara mendalam. Berikut merupakan karakteristik produktivitas apel.



**Gambar 4.7** Karakteristik Produktivitas Apel di Kota Batu

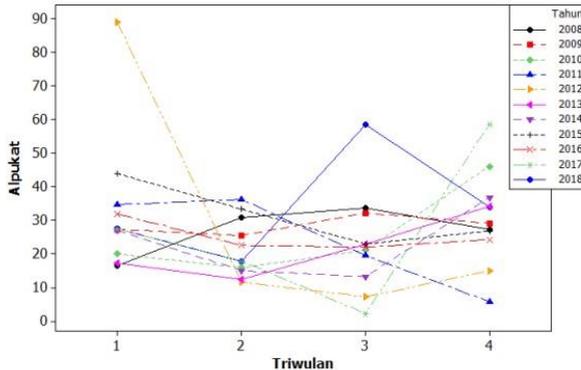
Produktivitas apel mengindikasikan berpola musiman berdasarkan Gambar 4.7. Pola yang sama setiap tahun ditunjukkan dengan meningkatnya produktivitas pada triwulan II, kemudian menurun pada triwulan III, dan meningkat lagi pada triwulan IV. Produktivitas buah apel pada tahun 2008 sampai tahun 2011 sempat terjadi kenaikan yang sangat signifikan, dimana pada tahun 2010 tersebut Kota Batu dinobatkan sebagai Kota Apel karena produksi Apel yang cukup banyak. Pada triwulan III tahun 2011 terjadi penurunan yang disusul penurunan drastis di triwulan IV tahun 2011, dimana produktivitas apel hanya 0.062 kg/pohon. Hal tersebut terjadi karena, banyak pohon yang di tebang dan di bongkar karena usianya sudah atau sudah tidak produktif sebanyak 289.090 pohon. Setelah periode tersebut, kemudian terjadi peningkatan pada beberapa periode dan kembali stabil sampai sekarang dengan rata-rata 8 kg/pohon. Selanjutnya merupakan analisis karakteristik produktivitas jeruk di Kota Batu sebagai berikut.



**Gambar 4.8** Karakteristik Produktivitas Jeruk di Kota Batu

Produktivitas jeruk cenderung berfluktuasi dan mengindikasikan berpola musiman yang ditunjukkan pada Gambar 4.8, dimana meningkat pada triwulan II dan menurun pada triwulan III. Produktivitas paling tinggi terjadi pada triwulan II 2008 yang mencapai 66 kg/pohon. Hal tersebut terjadi karena pada tahun 2006, jeruk keprok Batu 55 telah dilepas dan dinyatakan oleh pemerintah sebagai varietas jeruk unggul nasional berdasarkan Surat Keputusan Menteri Pertanian No. 307/Kpts/SR.120/4/2006, melengkapi varietas jeruk lain yang sudah ada. Berdasarkan ketetapan pemerintah ini, maka jeruk keprok Batu 55 sudah dapat dikembangkan secara bebas dan massal sebagai benih sebar untuk materi tanaman di lapang, dengan proses produksi sesuai dengan alur proses produksi pohon induk dan distribusi benih jeruk bebas penyakit yang telah diberlakukan pemerintah. Sehingga hal tersebut memicu para petani buah untuk ikut menanam buah pada tahun tersebut, sehingga terjadi panen yang melimpah di tahun 2008 karena pohon jeruk akan berbuah 3-4 tahun setelah penanaman. Pada periode selanjutnya, mengalami penurunan pada satu periode kemudian meningkat secara berangsur-angsur. Namun, pada keadaan sekarang produktivitas jeruk tidak stabil. Hal tersebut diindikasikan adanya proses belajar petani jeruk dalam proses

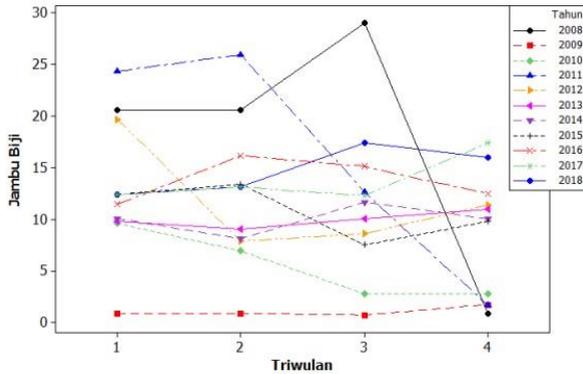
perawatan tanaman jeruk. Selanjutnya merupakan analisis karakteristik produktivitas alpukat di Kota Batu sebagai berikut.



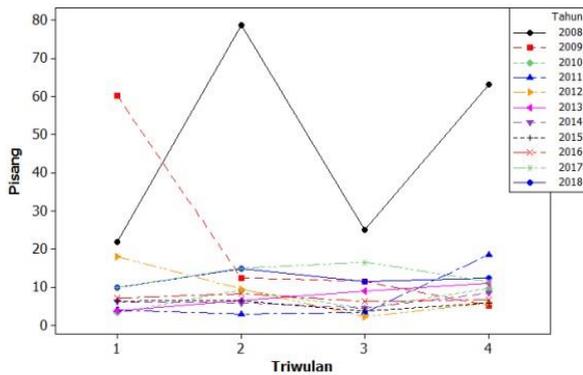
**Gambar 4.9** Karakteristik Produktivitas Alpukat di Kota Batu

Produktivitas buah alpukat cenderung berfluktuasi dan tidak berpola musiman ditunjukkan ada Gambar 4.9, dimana produktivitas paling tinggi terjadi pada triwulan I 2012 yaitu sebanyak 89 kg/pohon. Hal tersebut dikarenakan dari 50.428 pohon, yang sedang menghasilkan ada 33.687 pohon yang lebih banyak dibandingkan periode-periode yang lainnya. Sedangkan produktivitas buah alpukat paling sedikit pada triwulan III 2017 hanya sebanyak 3 kg/pohon. Selanjutnya merupakan analisis karakteristik produktivitas jambu biji di Kota Batu.

Karakteristik produktivitas jambu biji pada Gambar 4.10 dapat dilihat bahwa produktivitas buah jambu biji tidak berpola musiman dan lebih stabil pada akhir-akhir ini, walaupun sempat mengalami penurunan yang drastis pada triwulan IV tahun 2008 yang hanya 1kg/pohon. Rata-rata produktivitas buah jambu biji dalam keadaan stabil yang dimulai pada triwulan II 2012 sampai triwulan IV 2018 adalah 12 kg/pohon. Selanjutnya merupakan analisis karakteristik produktivitas pisang di Kota Batu pada Gambar 4.11.



**Gambar 4.10** Karakteristik Produktivitas Jambu Biji di Kota Batu

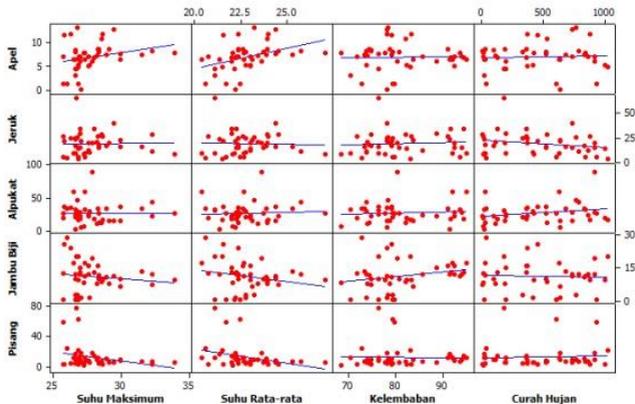


**Gambar 4.11** Karakteristik Produktivitas Pisang di Kota Batu

Produktivitas pisang tidak berpola musiman berdasarkan Gambar 4.11. Produktivitas pisang yang tinggi terjadi pada triwulan I 2008 sampai triwulan I 2009 dimana produktivitasnya mencapai 79 kg/pohon. Setelah periode tersebut, produktivitas buah pisang mengalami keadaan yang stabil dimana produktivitasnya 9 kg/pohon.

Hampir semua jenis buah paling banyak diproduksi di Kecamatan Bumiaji, karena daerah tersebut merupakan daerah

terbesar di Kota Batu dan sebagian besar daerahnya merupakan lahan pertanian dan hutan. Selanjutnya dilakukan analisis hubungan antara deret input yaitu suhu rata-rata, kelembaban, dan curah hujan dengan deret output yaitu produktivitas apel, jeruk, alpukat, jambu biji, dan pisang sebagai berikut.



**Gambar 4.12** Analisis Hubungan Deret Input dan Deret Output

Analisis hubungan ditunjukkan pada Gambar 4.12, diperoleh hasil bahwa pada produktivitas apel ada pola hubungan yang positif dengan suhu rata-rata atau suhu maksimum. Pada produktivitas jeruk dan alpukat tidak memiliki pola hubungan dengan deret *input*. Sedangkan, pada produktivitas jambu biji dan pisang ada pola hubungan yang negatif dengan suhu rata-rata atau suhu maksimum. Berdasarkan hal tersebut, maka akan dilakukan pemodelan produktivitas lima buah di Kota Batu tanpa pengaruh deret *input* dan dengan pengaruh deret *input*.

#### 4.2 Pemodelan Produktivitas Lima Buah di Kota Batu

Pemodelan terhadap lima buah di Kota Batu ini dilakukan dengan beberapa metode, salah satunya metode ARIMA. Pada pemodelan dengan ARIMA ini data dibagi menjadi data *training* dan data *testing*, dimana data *training* pada periode triwulan I tahun 2008 sampai triwulan IV tahun 2017. Sedangkan data

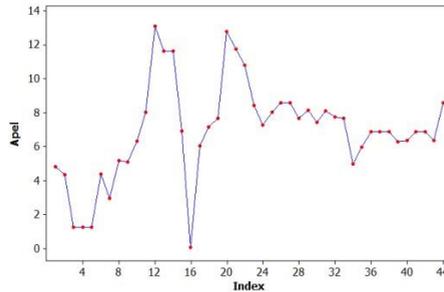
*testing* pada periode triwulan I tahun 2018 sampai triwulan IV tahun 2018.

#### 4.2.1 Pemodelan Produktivitas Lima Buah di Kota Batu dengan Metode ARIMA

Berikut merupakan pemodelan ARIMA produktivitas apel, jeruk, alpukat, jambu biji, dan pisang.

##### A. Pemodelan Produktivitas Apel

Tahap pertama pemodelan ARIMA adalah identifikasi stasioneritas dari data baik stasioner dalam *mean* maupun varians. Secara visual, dapat digambarkan pada *Time Series Plot* sebagai berikut.

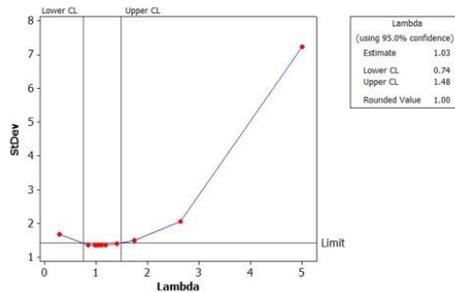


**Gambar 4.13** *Time Series Plot* Produktivitas Apel

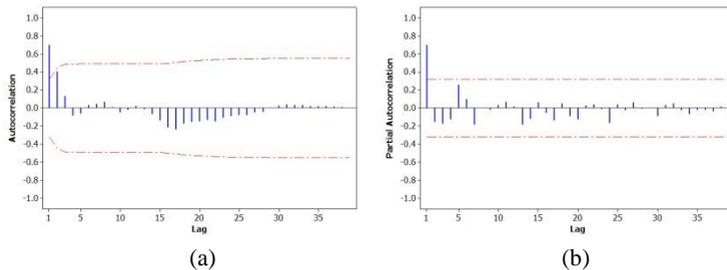
Berdasarkan Gambar 4.13 dapat dilihat secara visual bahwa data produktivitas apel di kota Batu tidak stasioner dalam *mean* karena memiliki pola tren naik, walaupun pada  $t=24$  sampai  $t=44$  kemudian stabil. Produktivitas apel juga diindikasikan memiliki pola musiman. Pola yang sama setiap tahun ditunjukkan dengan meningkatnya produktivitas pada triwulan II, kemudian menurun pada triwulan III, dan meningkat lagi pada triwulan IV. Selanjutnya dilakukan pemeriksaan kestasioneran dapat dilakukan dalam varians menggunakan transformasi *Box-Cox* sebagai berikut.

Nilai *rounded value* yang ditunjukkan pada Gambar 4.14 sebesar 1 sehingga dapat dikatakan bahwa produktivitas telah stasioner dalam

varians. Selanjutnya dilakukan pemeriksaan plot ACF dan PACF untuk melakukan pemeriksaan kestasioneran dalam mean sebagai berikut.



**Gambar 4.14 Transformasi Box Cox Produktivitas Apel**

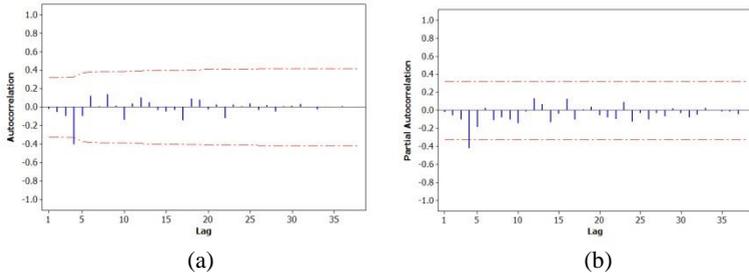


**Gambar 4.15 Plot (a) ACF (b) PACF Produktivitas Apel**

Plot ACF (a) dan PACF (b) pada Gambar 4.15 menunjukkan nilai autokorelasinya mendekati satu dan cenderung turun secara lambat, sehingga produktivitas apel dikatakan tidak stasioner dalam mean. Maka akan dilakukan *differencing* satu terhadap data. Berikut merupakan plot ACF dan PACF hasil *differencing*.

Setelah dilakukan *differencing* diketahui bahwa produktivitas apel telah stasioner dalam mean yang ditunjukkan pada Gambar 4.15, selanjutnya akan dilakukan penentuan model berdasarkan *lag-lag* yang signifikan pada plot ACF dan PACF. Plot ACF dan PACF menunjukkan *lag* yang signifikan sama yaitu *lag* ke-4. Diperoleh model dugaan awal adalah ARIMA

$(0,1,0)(1,0,0)^4$  dan ARIMA  $(0,1,0)(0,0,1)^4$  dengan estimasi parameter dijelaskan sebagai berikut pada Tabel 4.2.



**Gambar 4.16** Plot (a) ACF (b) PACF Produktivitas Apel Setelah *Differencing*

**Tabel 4.2** Pengujian Parameter Model ARIMA pada Produktivitas Apel

Model ARIMA	Parameter	Estimasi	SE	t-value	P-Value
$(0,1,0)(1,0,0)^4$	$\Phi_4$	-0,41	0,15	-2,37	0,0095
$(0,1,0)(0,0,1)^4$	$\Theta_4$	0,33	0,15	2,14	0,0389

Hasil pengujian parameter pada Tabel 4.2 menunjukkan bahwa semua parameter model ARIMA  $(0,1,0)(1,0,0)^4$  dan ARIMA  $(0,1,0)(0,0,1)^4$  signifikan, selanjutnya dilakukan pengujian diagnosa dengan menggunakan Uji Ljung-Box dan pengujian asumsi residual berdistribusi normal *Kolmogrov-Smirnov* dengan hasil pada Lampiran 3. Berdasarkan hasil pada Lampiran 3 menunjukkan bahwa model ARIMA  $(0,1,0)(1,0,0)^4$  dan ARIMA  $(0,1,0)(0,0,1)^4$  memenuhi asumsi residual *white noise* dan residual berdistribusi normal. Selanjutnya dilakukan pemilihan model terbaik dengan menggunakan perbandingan nilai RMSEP dan MAPEP. Pemilihan model terbaik ini digunakan karena kedua model memenuhi asumsi pemodelan ARIMA.

Hasil perhitungan nilai RMSEP dan MAPEP pada Tabel 4.3 menunjukkan bahwa model terbaik adalah ARIMA

$(0,1,0)(0,0,1)^4$  karena memiliki nilai RMSEP dan MAPEP terkecil. Berikut merupakan persamaan ARIMA  $(0,1,0)(0,0,1)^4$ :

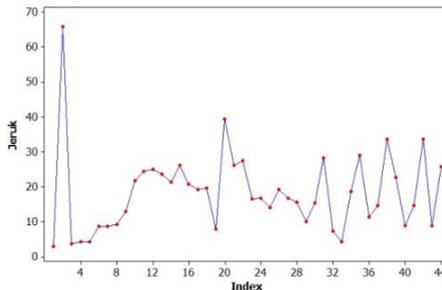
$$Y_{1,t} = Y_{1,t-1} - 0,33a_{1,t-4} + a_{1,t}$$

**Tabel 4.3** Pemilihan Model ARIMA Terbaik pada Produktivitas Apel

Model ARIMA	RMSEP	MAPEP
$(0,1,0)(1,0,0)^4$	1,07	10,58
<b><math>(0,1,0)(0,0,1)^4</math></b>	<b>1,04</b>	<b>9,93</b>

## B. Pemodelan Produktivitas Jeruk

Tahap pertama pemodelan ARIMA adalah identifikasi stasioneritas dari data baik stasioner dalam *mean* maupun varians. Secara visual, dapat digambarkan pada *Time Series Plot* sebagai berikut.

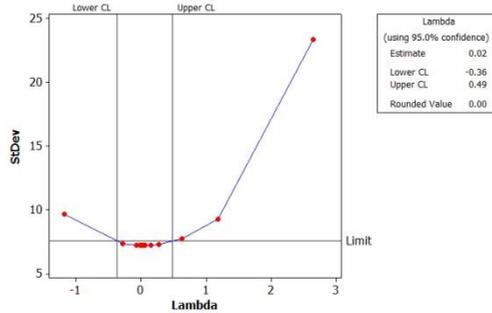


**Gambar 4.17** *Time Series Plot* Produktivitas Jeruk

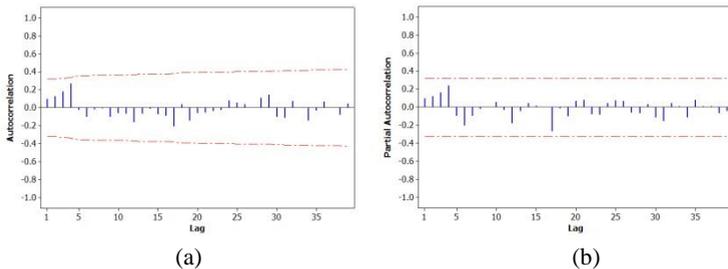
Plot *Time Series* pada Gambar 4.17 menunjukkan bahwa data produktivitas jeruk di kota Batu tidak stasioner dalam *mean* karena memiliki pola berfluktuasi, walaupun pada  $t=29$  sampai  $t=44$  kemudian stabil. Selanjutnya dilakukan pemeriksaan kestasioneran dapat dilakukan dalam varians menggunakan transformasi *Box-Cox* pada Gambar 4.18.

Nilai *rounded value* sebesar 0 berdasarkan Gambar 4.18, sehingga dapat dikatakan bahwa produktivitas jeruk belum stasioner dalam varians. Kemudian dilakukan transformasi  $\ln(Z_t)$  agar data stasioner dalam *varians*. Hasil pemeriksaan transformasi *Box-Cox* dilihat pada Lampiran 4 diperoleh nilai lamda sebesar 1, sehingga produktivitas jeruk dikatakan telah

stasioner dalam varians. Selanjutnya dilakukan pemeriksaan plot ACF dan PACF pada Gambar 4.19.



**Gambar 4.18** Transformasi Box Cox Produktivitas Jeruk



**Gambar 4.19** Plot (a) ACF (b) PACF Produktivitas Jeruk

Plot ACF (a) dan PACF (b) produktivitas jeruk yang ditunjukkan pada Gambar 4.19 diperoleh hasil bahwa tidak ada *lag* yang signifikan. Sehingga model yang sesuai adalah ARIMA (0,0,0). Hal tersebut dikarenakan jumlah data yang tidak besar, maka akan dicobakan order model yang diindikasikan oleh plot ACF dan PACF yang mendekati batas. Berdasarkan plot ACF dan PACF, *lag* yang mendekati batas adalah *lag* ke-4. Sehingga model dugaan awal adalah ARIMA (1,0,0)<sup>4</sup> dan ARIMA (0,0,1)<sup>4</sup> dengan estimasi parameter dijelaskan pada Tabel 4.4.

Hasil pengujian parameter model ARIMA produktivitas jeruk ditunjukkan pada Tabel 4.4 dimana diketahui bahwa semua parameter model ARIMA (1,0,0)<sup>4</sup> dan ARIMA (0,0,1)<sup>4</sup> signifikan pada taraf nyata sebesar 10%.

**Tabel 4.4** Pengujian Parameter Model ARIMA pada Produktivitas Jeruk

Model ARIMA	Parameter	Estimasi	SE	t-value	P-Value
$(1,0,0)^4$	$\mu$	2,67	0,14	18,68	<0,0001
	$\Phi_4$	0,29	0,16	1,8	0,0791
$(0,0,1)^4$	$\mu$	2,68	0,13	20,26	<0,0001
	$\Theta_4$	-0,28	0,16	-1,73	0,0924

Selanjutnya dilakukan pengujian diagnosa dengan menggunakan Uji Ljung-Box dan pengujian asumsi residual berdistribusi normal *Kolmogrov-Smirnov* dengan hasil pada Lampiran 4. Berdasarkan hasil pada Lampiran 4 menunjukkan bahwa model ARIMA  $(1,0,0)^4$  dan ARIMA  $(0,0,1)^4$  memenuhi asumsi residual *white noise* dan residual berdistribusi normal. Selanjutnya dilakukan pemilihan model terbaik dengan menggunakan perbandingan nilai RMSEP dan MAPEP. Pemilihan model terbaik ini digunakan karena kedua model memenuhi asumsi pemodelan ARIMA.

**Tabel 4.5** Pemilihan Model ARIMA Terbaik pada Produktivitas Jeruk

Model ARIMA	RMSEP	MAPEP
$(1,0,0)^4$	<b>7,67</b>	<b>28,44</b>
$(0,0,1)^4$	7,98	32,78

Hasil perhitungan nilai RMSEP dan MAPEP pada Tabel 4.5 menunjukkan bahwa model terbaik adalah ARIMA  $(1,0,0)^4$  karena memiliki nilai RMSEP dan MAPEP terkecil. Berikut merupakan persamaan ARIMA  $(1,0,0)^4$ :

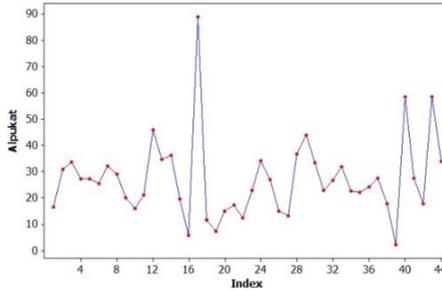
$$Y_{2,t} = 1,89 + 0,29Y_{2,t-4} + a_{2,t}$$

### C. Pemodelan Produktivitas Alpukat

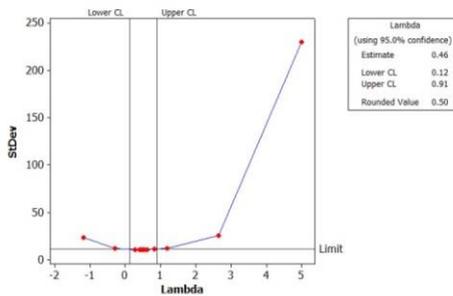
Sebelum dilakukan pemodelan ARIMA, terlebih dahulu dilakukan identifikasi stasioneritas dari data baik stasioner dalam *mean* maupun varians. Secara visual, dapat digambarkan pada *Time Series Plot* pada Gambar 4.20.

Produktivitas jeruk di kota Batu berdasarkan Gambar 4.20 dapat dilihat bahwa data tidak stasioner dalam *mean* karena memiliki pola berfluktuasi. Selanjutnya dilakukan pemeriksaan

kestasioneran dapat dilakukan dalam varians menggunakan transformasi *Box-Cox* pada Gambar 4.21.

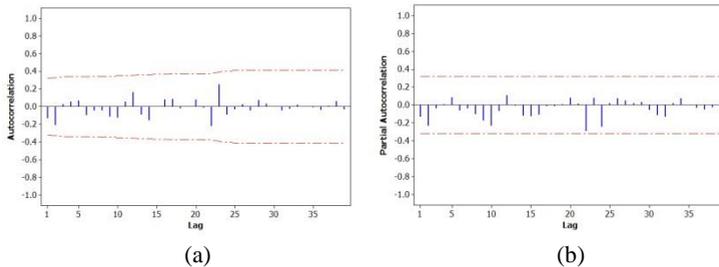


**Gambar 4.20** Time Series Plot Produktivitas Alpakat



**Gambar 4.21** Transformasi Box Cox Produktivitas Alpakat

Nilai *rounded value* yang ditunjukkan pada Gambar 4.21 menunjukkan bahwa nilai *rounded value* sebesar 0.5 sehingga dapat dikatakan bahwa produktivitas alpukat belum stasioner dalam varians. Kemudian dilakukan transformasi Akar pangkat 2 dari ( $Z_t$ ) agar data stasioner dalam *variens*. Hasil pemeriksaan transformasi *Box-Cox* dapat dilihat pada Lampiran 5 yang diperoleh nilai lamda sebesar 1, sehingga produktivitas alpukat dikatakan telah stasioner dalam varians. Selanjutnya dilakukan pemeriksaan plot ACF dan PACF pada Gambar 4.22.



**Gambar 4.22** Plot (a) ACF (b) PACF Produktivitas Alpkat

Plot ACF (a) dan PACF (b) pada Gambar 4.22 diperoleh hasil bahwa tidak ada *lag* yang signifikan. Sehingga model yang sesuai adalah ARIMA (0,0,0). Hal tersebut dikarenakan jumlah data yang tidak besar, maka akan dicobakan order model yang diindikasikan oleh plot ACF dan PACF yang mendekati batas. Berdasarkan plot ACF, *lag* yang mendekati batas adalah *lag* ke-2. Sedangkan plot PACF, *lag* yang mendekati batas adalah *lag* ke-22. Sehingga model dugaan awal adalah ARIMA (0,0,[2]), ARIMA ([22],0,0), dan ARIMA ([22],0,[2]) dengan estimasi parameter dijelaskan sebagai berikut.

**Tabel 4.6** Pengujian Parameter Model ARIMA pada Produktivitas Alpkat

Model ARIMA	Parameter	Estimasi	SE	t-value	P-Value
(0,0,[2])	$\mu$	4,96	0,16	31,4	<0,0001
	$\theta_2$	0,29	0,18	1,64	0,1096
([22],0,0)	$\mu$	5,01	0,17	28,69	<0,0001
	$\phi_{22}$	-0,45	0,22	-2,07	0,0454
([22],0,[2])	$\mu$	5,01	0,12	42,97	<0,0001
	$\theta_2$	0,32	0,16	1,99	0,0537
	$\phi_{22}$	-0,5	0,22	-2,32	0,0258

Hasil pengujian parameter pada Tabel 4.6 dapat diketahui bahwa semua parameter model ARIMA (0,0,[2]) tidak signifikan pada taraf signifikansi 10%, sedangkan parameter model ARIMA ([22],0,0) dan ARIMA ([22],0,[2]) signifikan pada taraf signifikansi 10%. Selanjutnya dilakukan pengujian diagnosa dengan menggunakan Uji Ljung-Box dan pengujian asumsi

residual berdistribusi normal *Kolmogrov-Smirnov* dengan hasil pada Lampiran 5. Berdasarkan hasil pada Lampiran 5 menunjukkan bahwa model ARIMA (0,0,[2]), ARIMA ([22],0,0), dan ARIMA ([22],0,[2]) memenuhi asumsi residual *white noise* dan residual berdistribusi normal. Selanjutnya dilakukan pemilihan model terbaik dengan menggunakan perbandingan nilai RMSEP dan MAPEP pada model ARIMA ([22],0,0) dan ARIMA ([22],0,[2]). Pemilihan model terbaik ini digunakan karena kedua model memenuhi asumsi pemodelan ARIMA.

**Tabel 4.7** Pemilihan Model ARIMA Terbaik pada Produktivitas Alpukat

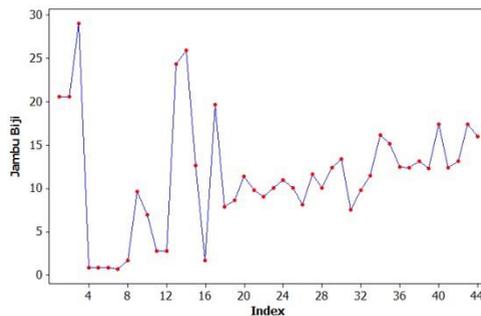
Model ARIMA	RMSEP	MAPEP
<b>([22],0,0)</b>	<b>24,79</b>	<b>886,15</b>
([22],0,[2])	27,92	978,57

Hasil perhitungan nilai RMSEP dan MAPEP pada Tabel 4.7 menunjukkan bahwa model terbaik adalah ARIMA ([22],0,0) karena memiliki nilai RMSEP dan MAPEP terkecil. Berikut merupakan persamaan ARIMA ([22],0,0):

$$Y_{3,t} = 7,28 - 0,45Y_{3,t-22} + a_{3,t}$$

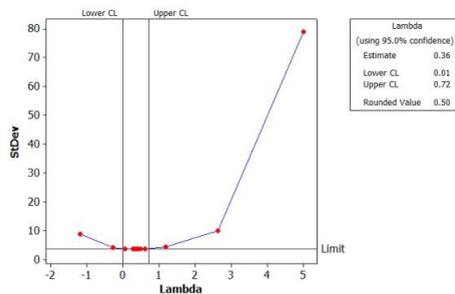
#### D. Pemodelan Produktivitas Jambu Biji

Tahap pertama pemodelan ARIMA adalah identifikasi stasioneritas dari data baik stasioner dalam *mean* maupun varians. Secara visual, dapat digambarkan pada *Time Series Plot* sebagai berikut.



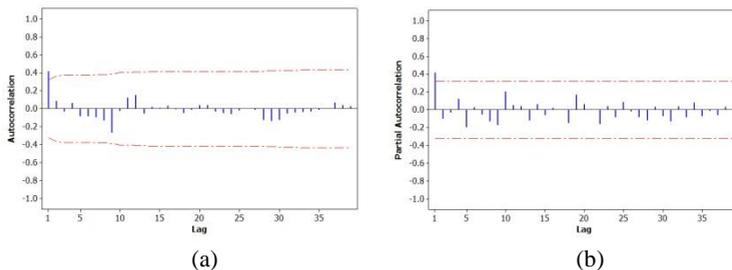
**Gambar 4.23** *Time Series Plot* Produktivitas Jambu Biji

Plot *Time Series* pada Gambar 4.23 dapat dilihat secara visual bahwa data produktivitas alpukat di kota Batu tidak stasioner dalam *mean* karena memiliki pola tren naik. Selanjutnya dilakukan pemeriksaan kestasioneran dapat dilakukan dalam *varians* menggunakan transformasi *Box-Cox* pada Gambar 4.24.



**Gambar 4.24** Transformasi *Box Cox* Produktivitas Jambu Biji

Nilai *rounded value* sebesar 0.5 yang ditunjukkan pada Gambar 4.24, sehingga dapat dikatakan bahwa produktivitas jambu biji belum stasioner dalam *varians*. Kemudian dilakukan transformasi Akar pangkat 2 dari ( $Z_t$ ) agar data stasioner dalam *varians*. Hasil pemeriksaan transformasi *Box-Cox* dapat dilihat pada Lampiran 6 yang diperoleh nilai lamda sebesar 0.5 dan selang interval melalui 1, sehingga produktivitas jambu biji dikatakan telah stasioner dalam *varians*. Selanjutnya dilakukan pemeriksaan plot ACF dan PACF pada Gambar 4.25.



**Gambar 4.25** Plot (a) ACF (b) PACF Produktivitas Jambu Biji

Plot ACF (a) dan PACF (b) produktivitas jambu biji yang ditunjukkan pada Gambar 4.25 menunjukkan bahwa *lag* yang signifikan yaitu *lag* ke-1. Diperoleh model dugaan awal adalah ARIMA (1,0,0) dan ARIMA (0,0,1) dengan estimasi parameter dijelaskan sebagai berikut.

**Tabel 4.8** Pengujian Parameter Model ARIMA pada Produktivitas Jambu Biji

Model ARIMA	Parameter	Estimasi	SE	t-value	P-Value
(1,0,0)	$\mu$	3,18	0,29	10,98	<0,0001
	$\phi_1$	0,43	0,15	2,88	0,0065
(0,0,1)	$\mu$	3,15	0,23	13,44	<0,0001
	$\theta_1$	-0,39	0,15	-2,55	0,0148

Hasil pengujian parameter model ARIMA produktivitas jambu biji ditunjukkan pada Tabel 4.8 dimana dapat diketahui bahwa semua parameter model ARIMA (1,0,0) dan ARIMA (0,0,1) signifikan pada taraf signifikan 5%. Selanjutnya dilakukan pengujian diagnosa dengan menggunakan Uji Ljung-Box dan pengujian asumsi residual berdistribusi normal *Kolmogrov-Smirnov* dengan hasil pada Lampiran 6. Berdasarkan hasil pada Lampiran 6 menunjukkan bahwa model ARIMA (1,0,0) dan ARIMA (0,0,1) memenuhi asumsi residual *white noise* dan berdistribusi normal. Selanjutnya dilakukan pemilihan model terbaik dengan menggunakan perbandingan nilai RMSEP dan MAPEP. Pemilihan model terbaik ini digunakan karena kedua model memenuhi asumsi pemodelan ARIMA.

**Tabel 4.9** Pemilihan Model ARIMA Terbaik pada Produktivitas Jambu Biji

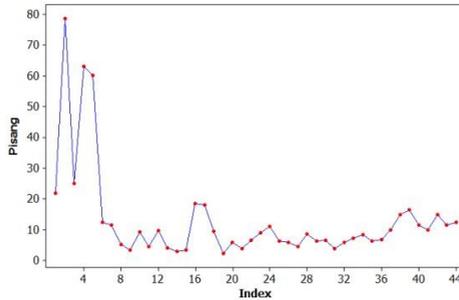
Model ARIMA	RMSEP	MAPEP
<b>(1,0,0)</b>	<b>1,32</b>	<b>9,39</b>
(0,0,1)	2,05	13,74

Hasil perhitungan nilai RMSEP dan MAPEP pada Tabel 4.9 menunjukkan bahwa model terbaik adalah ARIMA (1,0,0) karena memiliki nilai RMSEP dan MAPEP terkecil. Berikut merupakan persamaan ARIMA (1,0,0):

$$Y_{4,t} = 1,82 + 0,4284Y_{4,t-1} + a_{4,t}$$

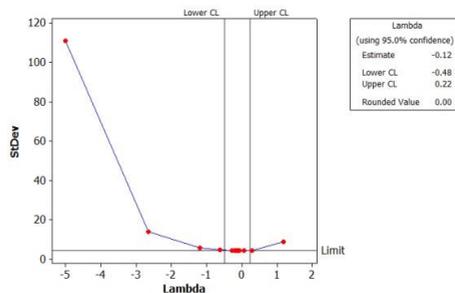
## E. Pemodelan Produktivitas Pisang

Sebelum melakukan pemodelan ARIMA, dilakukan terlebih dahulu identifikasi stasioneritas dari data baik stasioner dalam *mean* maupun *varians*. Secara visual, dapat digambarkan pada *Time Series Plot* pada Gambar 4.26.



**Gambar 4.26** *Time Series Plot* Produktivitas Pisang

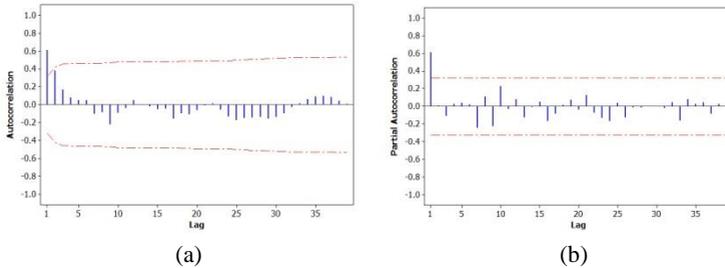
Produktivitas alpukat di kota Batu tidak stasioner dalam *mean* karena memiliki pola tren naik dan fluktuasi yang tinggi ditunjukkan pada Gambar 4.26. Selanjutnya dilakukan pemeriksaan kestasioneran dapat dilakukan dalam *varians* menggunakan transformasi *Box-Cox* sebagai berikut.



**Gambar 4.27** *Transformasi Box Cox* Produktivitas Pisang

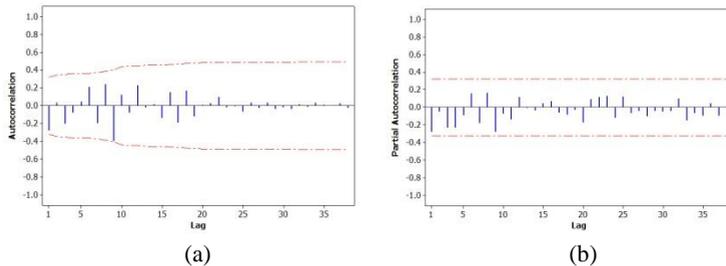
Nilai *rounded value* sebesar 0 yang ditunjukkan pada Gambar 4.27, sehingga dapat dikatakan bahwa produktivitas pisang belum stasioner dalam *varians*. Kemudian dilakukan transformasi  $\ln(Z_t)$  agar data stasioner dalam *varians*. Hasil pemeriksaan transformasi *Box-Cox*

dapat dilihat pada Lampiran 7 yang diperoleh nilai lamda sebesar 0.5 dan selang interval melalui 1, sehingga produktivitas pisang dikatakan telah stasioner dalam varians. Selanjutnya dilakukan pemeriksaan plot ACF dan PACF sebagai berikut.



**Gambar 4.28** Plot (a) ACF (b) PACF Produktivitas Pisang

Plot ACF (a) dan PACF (b) menunjukkan kecenderungan turun secara lambat pada Gambar 4.28, sehingga dikatakan tidak stasioner dalam mean. Maka akan dilakukan *differencing* satu terhadap data. Berikut merupakan plot ACF dan PACF hasil *differencing*.



**Gambar 4.29** Plot (a) ACF (b) PACF Produktivitas Pisang  
Setelah *Differencing*

Setelah dilakukan *differencing*, pada Gambar 4.29 diketahui bahwa produktivitas pisang telah stasioner dalam mean. Selanjutnya akan dilakukan penentuan model berdasarkan *lag-lag* yang signifikan pada plot ACF dan PACF. Berdasarkan gambar di atas diperoleh hasil bahwa tidak ada *lag* yang signifikan. Sehingga model yang sesuai adalah ARIMA (0,0,0). Hal tersebut dikarenakan jumlah data yang tidak besar, maka akan dicobakan

order model yang diindikasikan oleh plot ACF dan PACF yang mendekati batas. Berdasarkan plot ACF dan PACF, *lag* yang mendekati batas adalah *lag* ke-9. Sehingga model dugaan awal adalah ARIMA ([9],1,0) dan ARIMA (0,1,[9]) dengan estimasi parameter dijelaskan sebagai berikut.

**Tabel 4.10** Pengujian Parameter Model ARIMA pada Produktivitas Pisang

Model ARIMA	Parameter	Estimasi	SE	t-value	P-Value
([9],1,0)	$\phi_9$	-0,42	0,15	-2,75	0,0091
(0,1,[9])	$\theta_9$	0,37	0,16	2,29	0,0279

Hasil pengujian estimasi parameter berdasarkan Tabel 4.10 dapat diketahui bahwa semua parameter model ARIMA ([9],1,0) dan ARIMA (0,1,[9]) signifikan pada taraf signifikansi 5%. Selanjutnya dilakukan pengujian diagnosa dengan menggunakan Uji Ljung-Box dan pengujian asumsi residual berdistribusi normal *Kolmogrov-Smirnov* dengan hasil pada Lampiran 7. Berdasarkan hasil pada Lampiran 7 menunjukkan bahwa model ARIMA ([9],1,0) dan ARIMA (0,1,[9]) memenuhi asumsi residual *white noise* dan residual berdistribusi normal. Selanjutnya dilakukan pemilihan model terbaik dengan menggunakan perbandingan nilai RMSEP dan MAPEP. Pemilihan model terbaik ini digunakan karena kedua model memenuhi asumsi pemodelan ARIMA.

**Tabel 4.11** Pemilihan Model ARIMA Terbaik pada Produktivitas Pisang

Model ARIMA	RMSEP	MAPEP
<b>([9],1,0)</b>	<b>3,84</b>	<b>24,88</b>
(0,1,[9])	3,86	24,94

Hasil perhitungan nilai RMSEP dan MAPEP pada Tabel 4.11 menunjukkan hasil bahwa model ARIMA ([9],1,0) adalah model terbaik karena memiliki nilai RMSEP dan MAPEP terkecil. Berikut merupakan persamaan ARIMA ([9],1,0):

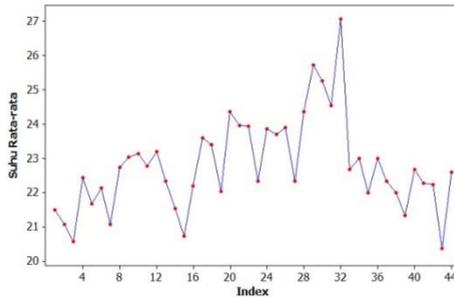
$$Y_{5,t} = Y_{5,t-1} - 0,42Y_{5,t-9} + 0,42Y_{5,t-10} + a_{5,t}$$

#### 4.2.2 Pemodelan Produktivitas Lima Buah di Kota Batu dengan Metode Fungsi Transfer

Sebelum melakukan pemodelan analisis fungsi transfer terlebih dahulu dilakukan pemodelan deret input dengan menggunakan ARIMA.

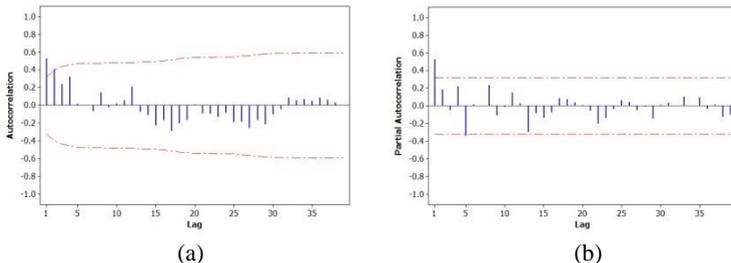
##### A. Pemodelan Deret Input Suhu Rata-rata

Pemodelan ARIMA pada deret *input* suhu didahului dengan identifikasi stasioneritas dari data baik stasioner dalam *mean* maupun varians. Secara visual, dapat digambarkan pada *Time Series Plot* sebagai berikut.



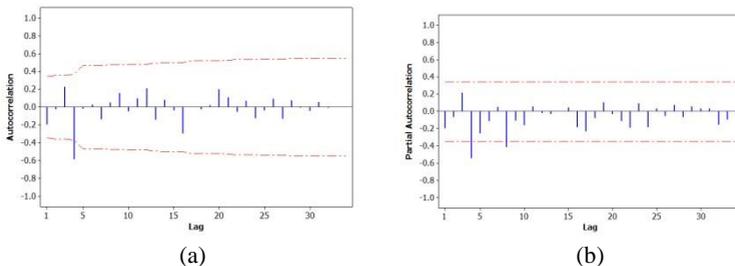
Gambar 4.30 *Time Series Plot* Suhu Rata-rata

Berdasarkan Gambar 4.30 dapat dilihat secara visual bahwa data suhu rata-rata di kota Batu tidak stasioner dalam *mean* karena memiliki pola tren naik dan turun. Selanjutnya dilakukan pemeriksaan plot ACF dan PACF sebagai berikut.



Gambar 4.31 Plot (a) ACF (b) PACF Suhu Rata-rata

Plot ACF (a) dan PACF (b) pada Gambar 4.31 menunjukkan kecenderungan turun secara lambat dan mengindikasikan adanya musiman, sehingga dikatakan tidak stasioner dalam mean. Pola musiman berulang setiap tahun, sehingga disebut pola musiman 4. Dimana terjadi penurunan suhu pada triwulan II dan III, kemudian mengalami peningkatan pada triwulan IV. Maka akan dilakukan *differencing* satu dan musiman 4 terhadap data. Berikut merupakan plot ACF dan PACF hasil *differencing*.



**Gambar 4.32** Plot (a) ACF (b) PACF Suhu Rata-rata Setelah *Differencing*

Setelah dilakukan *differencing*, plot ACF dan PACF ditunjukkan pada Gambar 4.32 yang diketahui bahwa suhu rata-rata telah stasioner dalam mean, selanjutnya akan dilakukan penentuan model berdasarkan *lag-lag* yang signifikan pada plot ACF dan PACF. Plot ACF (a) menunjukkan bahwa *lag* yang signifikan adalah *lag* ke-4 dan plot PACF (b) menunjukkan bahwa *lag* yang signifikan adalah *lag* ke-4,8. Diperoleh model dugaan awal adalah ARIMA  $(0,1,0)(0,1,1)^4$ , ARIMA  $(0,1,0)(1,1,0)^4$ , dan ARIMA  $(0,1,0)(2,1,0)^4$  dengan estimasi parameter dijelaskan pada Tabel 4.12.

**Tabel 4.12** Pengujian Parameter Model ARIMA pada Suhu Rata-rata

Model ARIMA	Parameter	Estimasi	SE	t-value	P-Value
$(0,1,0)(0,1,1)^4$	$\Theta_4$	0,97	0,08	12	<0,0001
$(0,1,0)(1,1,0)^4$	$\Phi_4$	-0,73	0,14	-5,2	<0,0001
$(0,1,0)(2,1,0)^4$	$\Phi_4$	-0,98	0,16	-6,14	<0,0001
	$\Phi_8$	-0,72	0,26	-2,81	0,0083

Hasil pengujian parameter model ARIMA pada suhu ditunjukkan pada Tabel 4.12 yang diperoleh hasil bahwa parameter model ARIMA  $(0,1,0)(0,1,1)^4$ , ARIMA  $(0,1,0)(1,1,0)^4$ , dan ARIMA  $(0,1,0)(2,1,0)^4$  signifikan pada taraf 5%. Selanjutnya dilakukan pengujian diagnosa dengan menggunakan Uji Ljung-Box dan pengujian asumsi residual berdistribusi normal *Kolmogrov-Smirnov* dengan hasil pada Lampiran 8. Berdasarkan hasil pada Lampiran 8 menunjukkan bahwa model ARIMA  $(0,1,0)(0,1,1)^4$ , ARIMA  $(0,1,0)(1,1,0)^4$ , dan ARIMA  $(0,1,0)(2,1,0)^4$  memenuhi asumsi residual *white noise* dan residual berdistribusi normal. Selanjutnya dilakukan pemilihan model terbaik dengan menggunakan perbandingan nilai RMSEP dan MAPEP. Pemilihan model terbaik ini digunakan karena ketiga model memenuhi asumsi pemodelan ARIMA.

**Tabel 4.13** Pemilihan Model ARIMA Terbaik pada Suhu

Model ARIMA	RMSEP	MAPEP
<b><math>(0,1,0)(0,1,1)^4</math></b>	<b>0,48</b>	<b>2,04</b>
$(0,1,0)(1,1,0)^4$	2,7	12,07
$(0,1,0)(2,1,0)^4$	0,74	2,73

Hasil perhitungan nilai RMSEP dan MAPEP pada Tabel 4.13 menunjukkan bahwa model terbaik adalah ARIMA  $(0,1,0)(0,1,1)^4$  karena memiliki nilai RMSEP dan MAPEP terkecil. Secara matematis, model tersebut dapat ditulis sebagai berikut:

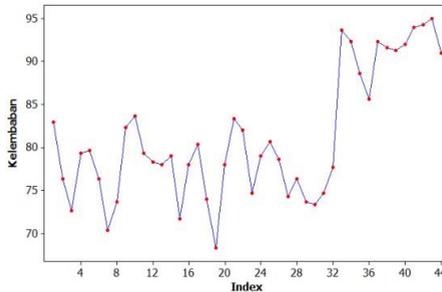
$$\alpha_{1t} = \frac{(1-B)(1-B^4)}{(1-0,97B^4)} X_{1,t}$$

Selanjutnya dilakukan proses *prewhitening* pada deret *output* sehingga dihasilkan deret  $\beta_{1t}$ . Persamaan matematis untuk deret  $\beta_{1t}$  adalah sebagai berikut:

$$\beta_{1t} = \frac{(1-B)(1-B^4)}{(1-0,97B^4)} Y_t$$

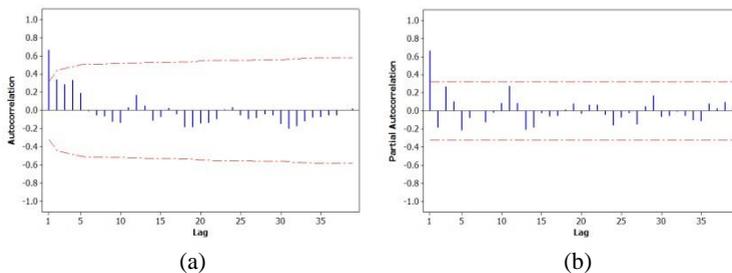
## B. Pemodelan Deret Input Kelembaban

Tahap pertama sebelum dilakukan pemodelan ARIMA adalah identifikasi stasioneritas dari data baik stasioner dalam *mean* maupun varians. Secara visual, dapat digambarkan pada *Time Series Plot* pada Gambar 4.33.



Gambar 4.33 *Time Series Plot* Kelembaban

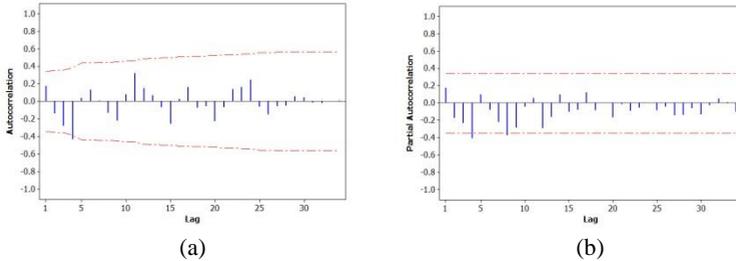
*Time Series Plot* ditunjukkan pada Gambar 4.33 dapat dilihat secara visual bahwa data kelembaban di kota Batu tidak stasioner dalam *mean* karena memiliki pola tren naik. Selanjutnya dilakukan pemeriksaan plot ACF dan PACF disajikan pada Gambar 4.34.



Gambar 4.34 Plot (a) ACF (b) PACF Kelembaban

Berdasarkan Gambar 4.34 plot ACF (a) dan PACF (b) menunjukkan kecenderungan turun secara lambat dan mengindikasikan adanya musiman, sehingga dikatakan tidak stasioner dalam *mean*. Pola musiman berulang setiap tahun, sehingga disebut pola musiman 4. Dimana terjadi penurunan

kelembaban pada triwulan II dan III, kemudian mengalami peningkatan pada triwulan IV. Maka akan dilakukan *differencing* satu dan empat terhadap data. Berikut merupakan plot ACF dan PACF hasil *differencing* pada Gambar 4.34.



**Gambar 4.35** Plot (a) ACF (b) PACF Kelembaban Setelah *Differencing*

Kelembaban telah stasioner dalam mean yang ditunjukkan oleh plot ACF dan PACF pada Gambar 4.35. Selanjutnya akan dilakukan penentuan model berdasarkan *lag-lag* yang signifikan pada plot ACF dan PACF. Plot ACF (a) menunjukkan bahwa *lag* yang signifikan adalah *lag* ke-4 dan plot PACF (b) menunjukkan bahwa *lag* yang signifikan adalah *lag* ke-4 dan ke-8. Diperoleh model dugaan awal adalah ARIMA  $(0,1,0)(0,1,1)^4$ , ARIMA  $(0,1,0)(1,1,0)^4$ , dan ARIMA  $(0,1,0)(2,1,0)^4$  dengan estimasi parameter dijelaskan pada Tabel 4.14.

**Tabel 4.14** Pengujian Parameter Model ARIMA pada Kelembaban

Model ARIMA	Parameter	Estimasi	SE	t-value	P-Value
$(0,1,0)(0,1,1)^4$	$\Theta_4$	0,7	0,15	4,8	<0,0001
$(0,1,0)(1,1,0)^4$	$\Phi_4$	-0,49	0,16	-3,01	0,0048
$(0,1,0)(2,1,0)^4$	$\Phi_4$	-0,63	0,16	-3,96	0,0004
	$\Phi_8$	-0,56	0,21	-2,62	0,0133

Parameter model ARIMA  $(0,1,0)(0,1,1)^4$ , ARIMA  $(0,1,0)(1,1,0)^4$ , dan ARIMA  $(0,1,0)(2,1,0)^4$  signifikan pada taraf signifikansi 5% yang ditunjukkan pada Tabel 4.14. Selanjutnya dilakukan pengujian diagnosa dengan menggunakan Uji Ljung-Box dan pengujian asumsi residual berdistribusi normal

*Kolmogrov-Smirnov* dengan hasil pada Lampiran 9. Berdasarkan hasil pada Lampiran 9 menunjukkan bahwa model ARIMA  $(0,1,0)(1,1,0)^4$  dan ARIMA  $(0,1,0)(2,1,0)^4$  memenuhi asumsi residual *white noise* dan residual berdistribusi normal, sedangkan model ARIMA  $(0,1,0)(0,1,1)^4$  tidak memenuhi asumsi residual *white noise* namun memenuhi asumsi residual berdistribusi normal. Selanjutnya dilakukan pemilihan model terbaik dengan menggunakan perbandingan nilai RMSEP dan MAPEP pada model ARIMA  $(0,1,0)(1,1,0)^4$  dan ARIMA  $(0,1,0)(2,1,0)^4$ . Pemilihan model terbaik ini digunakan karena kedua model memenuhi asumsi pemodelan ARIMA.

**Tabel 4.15** Pemilihan Model ARIMA Terbaik pada Produktivitas Kelembaban

Model ARIMA	RMSEP	MAPEP
$(0,1,0)(1,1,0)^4$	3,15	3,09
<b><math>(0,1,0)(2,1,0)^4</math></b>	<b>2,42</b>	<b>1,79</b>

Hasil perhitungan nilai RMSEP dan MAPEP pada Tabel 4.15 menunjukkan bahwa model terbaik adalah ARIMA  $(0,1,0)(2,1,0)^4$  karena memiliki nilai RMSEP dan MAPEP terkecil. Secara matematis, model tersebut dapat ditulis sebagai berikut:

$$\alpha_{2t} = [(1-B)(1-B^4)(1+0,63B^4 + 0,56B^8)]X_{2,t}$$

Selanjutnya dilakukan proses *prewhitening* pada deret *output* sehingga dihasilkan deret  $\beta_{2t}$ . Persamaan matematis untuk deret  $\beta_{2t}$  adalah sebagai berikut:

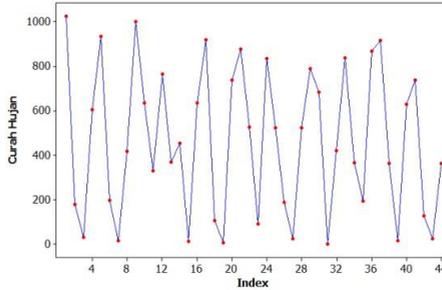
$$\beta_{2t} = [(1-B)(1-B^4)(1+0,63B^4 + 0,56B^8)]Y_t$$

### C. Pemodelan Deret Input Curah Hujan

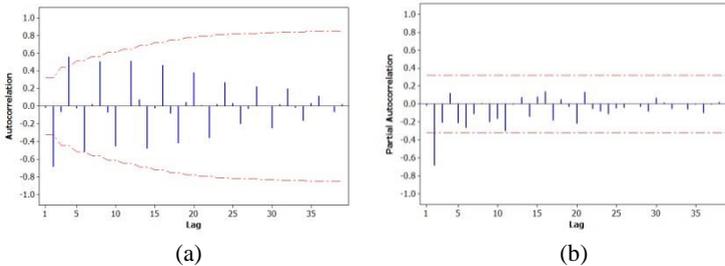
Tahap pertama sebelum dilakukan pemodelan ARIMA adalah identifikasi stasioneritas dari data baik stasioner dalam *mean* maupun varians. Secara visual, dapat digambarkan pada *Time Series Plot* pada Gambar 4.36.

Secara visual, curah hujan di kota Batu mengindikasikan adanya pola musiman 4 atau tahunan ditunjukkan pada Gambar 4.36. Dimana terjadi penurunan curah hujan pada triwulan II dan III, kemudian mengalami peningkatan pada triwulan IV dan

proses tersebut berlangsung setiap tahun. Curah hujan secara visual dikatakan tidak stasioner dalam *mean* karena memiliki pola tren turun. Selanjutnya dilakukan pemeriksaan plot ACF dan PACF pada Gambar 4.37.



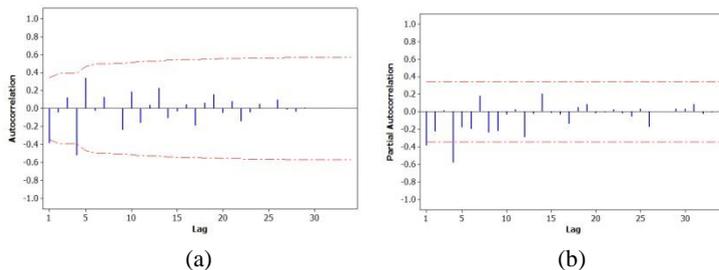
**Gambar 4.36** Time Series Plot Curah Hujan



**Gambar 4.37** Plot (a) ACF (b) PACF Curah Hujan

Plot ACF (a) dan PACF (b) menunjukkan kecenderungan turun secara lambat dan mengindikasikan adanya musiman pada Gambar 4.37, sehingga dikatakan tidak stasioner dalam *mean*. Maka akan dilakukan *differencing* satu dan musiman 4 terhadap data. Berikut merupakan plot ACF dan PACF hasil *differencing* pada Gambar 4.38.

Diketahui bahwa curah hujan telah stasioner dalam *mean* berdasarkan Gambar 4.38, selanjutnya akan dilakukan penentuan model berdasarkan *lag-lag* yang signifikan pada plot ACF dan PACF. Plot ACF (a) dan plot PACF (b) menunjukkan bahwa *lag* yang signifikan adalah *lag* ke-1 dan ke-4.



**Gambar 4.38** Plot (a) ACF (b) PACF Curah Hujan  
Setelah *Differencing*

Diperoleh model dugaan awal adalah ARIMA  $(0,1,1)(0,1,1)^4$ , ARIMA  $(1,1,0)(1,1,0)^4$ , dan ARIMA  $(0,1,1)(1,1,0)^4$  dengan estimasi parameter dijelaskan sebagai berikut.

**Tabel 4.16** Pengujian Parameter Model ARIMA pada Curah Hujan

Model ARIMA	Parameter	Estimasi	SE	t-value	P-Value
$(0,1,1)(0,1,1)^4$	$\theta_1$	0,38	0,13	3,01	0,0049
	$\Theta_4$	0,61	0,13	4,62	<0,0001
$(1,1,0)(1,1,0)^4$	$\varphi_1$	-0,32	0,14	-2,37	0,0237
	$\Phi_4$	-0,5	0,14	-3,6	0,001
$(0,1,1)(1,1,0)^4$	$\theta_1$	0,92	0,07	13,16	<0,0001
	$\Phi_4$	-0,53	0,15	-3,53	0,0012

Pengujian parameter berdasarkan Tabel 4.16 dapat diketahui bahwa semua parameter model ARIMA  $(0,1,1)(0,1,1)^4$ , ARIMA  $(1,1,0)(1,1,0)^4$ , dan ARIMA  $(0,1,1)(1,1,0)^4$  signifikan pada taraf signifikansi 5%. Selanjutnya dilakukan pengujian diagnosa dengan menggunakan Uji Ljung-Box dan pengujian asumsi residual berdistribusi normal *Kolmogrov-Smirnov* dengan hasil pada Lampiran 10. Berdasarkan hasil pada Lampiran 10 menunjukkan bahwa model ARIMA  $(0,1,1)(1,1,0)^4$  memenuhi asumsi residual *white noise* dan residual berdistribusi normal, sedangkan ARIMA  $(0,1,1)(0,1,1)^4$ , ARIMA  $(1,1,0)(1,1,0)^4$  tidak memenuhi asumsi residual *white noise* namun memenuhi asumsi residual berdistribusi normal. Berdasarkan hasil di atas, maka model terbaik untuk model ARIMA pada curah hujan adalah

ARIMA (0,1,1)(1,1,0)<sup>4</sup>. Secara matematis, model tersebut dapat ditulis sebagai berikut:

$$\alpha_{3t} = \frac{(1-B)(1-B^4)(1+0,53B^4)}{(1-0,92B)} X_{3,t}$$

Selanjutnya dilakukan proses *prewhitening* pada deret *output* sehingga dihasilkan deret  $\beta_{3t}$ . Persamaan matematis untuk deret  $\beta_{3t}$  adalah sebagai berikut:

$$\beta_{3t} = \frac{(1-B)(1-B^4)(1+0,53B^4)}{(1-0,92B)} Y_t$$

#### D. Pemodelan Fungsi Transfer pada Produktivitas Apel

Pemodelan fungsi transfer produktivitas apel dilakukan terhadap beberapa deret input yaitu suhu rata-rata, kelembaban, dan curah hujan.

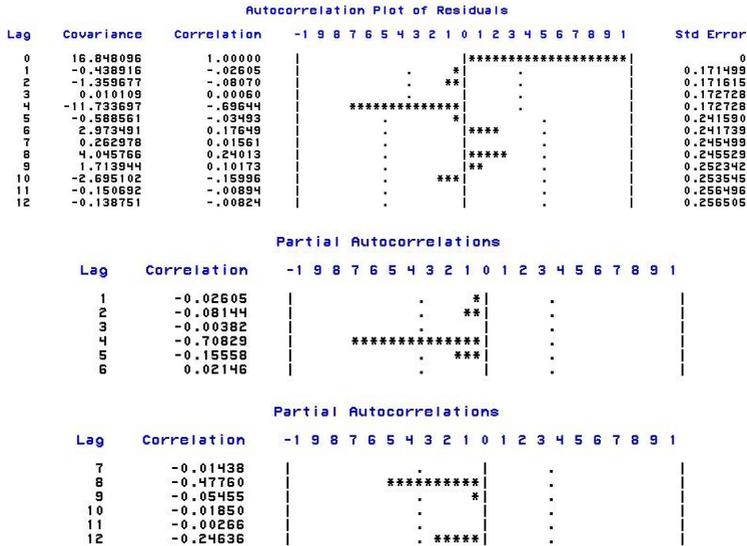
##### a. Pemodelan dengan Deret Input Suhu Rata-rata

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *prewhitening*. CCF digunakan untuk menentukan nilai orde ( $b, r, s$ ). Berikut merupakan plot CCF pada deret input suhu rata-rata dan deret output produktivitas apel.

Crosscorrelations			
Lag	Covariance	Correlation	-1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1
-12	0.496535	0.19660	.   ****
-11	0.465603	0.18439	.   ****
-10	0.045048	0.01784	.   .
-9	0.527510	0.20887	.   ****
-8	-0.058068	-0.0239	.   .
-7	0.012485	0.00494	.   .
-6	-0.128753	-0.05098	.   *
-5	0.209537	0.08297	.   **
-4	-0.448027	-0.17740	.   ****
-3	0.498510	0.19739	.   ****
-2	-0.379866	-0.14804	.   ***
-1	-0.485688	-0.19231	.   ****
0	0.215875	0.08548	.   **
1	0.642228	0.25429	.   *****
2	0.290074	0.11486	.   **
3	0.310572	0.12297	.   **
4	-0.184222	-0.07294	.   *
5	-0.338005	-0.13383	.   ***
6	-0.053281	-0.02110	.   .
7	-0.171240	-0.06780	.   *
8	-0.304537	-0.12058	.   **
9	0.270768	0.10721	.   **
10	0.202577	0.08021	.   **
11	0.133863	0.05300	.   *
12	-0.361690	-0.14321	.   ***

Gambar 4.39 CCF Produktivitas Apel dan Suhu Rata-rata

Plot CCF pada Gambar 4.39 diperoleh kemungkinan nilai orde  $(b,r,s)$  yaitu  $(b=1,r=0,s=0)$ . Selanjutnya dilakukan pemodelan ARMA terhadap deret *noise*. Berikut merupakan plot ACF dan PACF deret *noise* pada Gambar 4.40.



**Gambar 4.40** Plot ACF dan PACF Deret *Noise* Pemodelan Produktivitas Apel dan Suhu Rata-rata

Berdasarkan plot ACF dan PACF pada Gambar 4.40 maka model ARMA yang sesuai adalah  $ARMA(1,1)^4$ . Selanjutnya dilakukan pemodelan fungsi transfer antara model deret noise  $ARMA(1,1)^4$  dengan orde  $(b,r,s)$  yaitu  $(b=1,r=0,s=0)$ . Berikut merupakan pengujian parameter model.

**Tabel 4.17** Pengujian Parameter Model Fungsi Transfer Suhu dan Produktivitas Apel

Model	Parameter	Estimasi	SE	t-value	P-Value
$(b=1,r=0,s=0)$ $(P=1,Q=1,S=4)$	$\Theta_4$	0,59	0,18	3,3	0,0024
	$\Phi_4$	-0,5	0,19	-2,67	0,0119
	$\omega_0$	0,34	0,44	0,77	0,4465

Pengujian parameter pada Tabel 4.17 dapat dilihat bahwa orde  $(b,r,s)$  yaitu  $(b=1,r=0,s=0)$  tidak signifikan dalam model,

namun parameter model deret noise ARMA(1,1)<sup>4</sup> signifikan dalam model. Sehingga dapat dikatakan bahwa pemodelan produktivitas apel dengan deret *input* suhu rata-rata tidak dapat digunakan. Berarti produktivitas apel di Kota Batu tidak dipengaruhi suhu rata-rata.

### b. Pemodelan dengan Deret Input Kelembaban

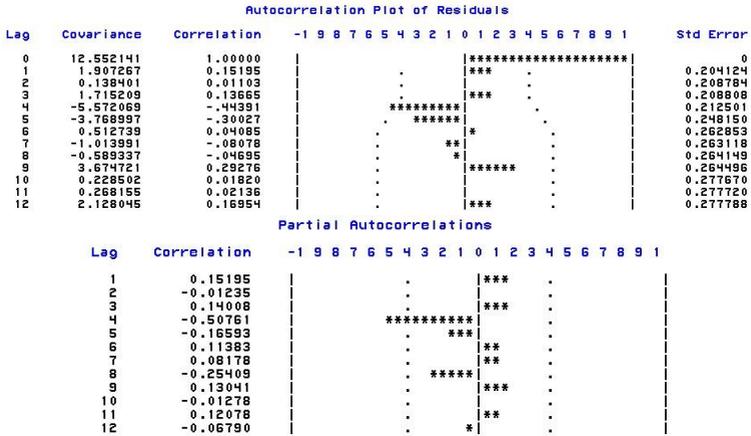
Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde ( $b,r,s$ ). Berikut merupakan plot CCF pada deret input kelembaban dan deret output produktivitas apel pada Gambar 4.41.

Crosscorrelations			
Lag	Covariance	Correlation	-1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1
-12	-0.639273	-0.04645	. . *
-11	-0.629153	-0.04571	. . *
-10	-0.611982	-0.04447	. . *
-9	-0.591192	-0.33359	*****
-8	0.320371	0.05351	. . *
-7	-0.282344	-0.02051	. . *
-6	-0.261240	-0.01898	. . *
-5	1.800008	0.13079	. . ***
-4	-1.175826	-0.08543	. . **
-3	2.274828	0.18529	. . ***
-2	2.186655	0.15359	. . ***
-1	-5.328587	-0.38717	*****
0	0.846863	0.06153	. . *
1	1.152894	0.08377	. . **
2	-0.229971	-0.01671	. . *
3	4.067993	0.29557	. . *****
4	-0.727839	-0.05288	. . *
5	-0.397637	-0.07176	. . *
6	-0.594026	-0.04316	. . *
7	-2.393464	-0.17391	. . ***
8	1.857743	0.13498	. . ***
9	0.461784	0.03355	. . *
10	0.045060	0.00327	. . *
11	3.811973	0.27697	. . *****
12	-1.695688	-0.12321	. . **

Gambar 4.41 CCF Produktivitas Apel dan Kelembaban

Berdasarkan Gambar 4.41 diperoleh kemungkinan nilai orde ( $b,r,s$ ) yaitu ( $b=[3],r=0,s=[8]$ ). Selanjutnya dilakukan pemodelan ARMA terhadap deret *noise*. Berikut merupakan plot ACF dan PACF deret *noise* pada Gambar 4.42.

Plot ACF dan PACF pada Gambar 4.42 menunjukkan bahwa model ARMA yang sesuai adalah ARMA(0,1)<sup>4</sup>. Selanjutnya dilakukan pemodelan fungsi transfer antara model deret noise ARMA(0,1)<sup>4</sup> dengan orde ( $b,r,s$ ) yaitu ( $b=[3],r=0,s=[8]$ ). Berikut merupakan pengujian parameter model pada Tabel 4.18.



**Gambar 4.42** Plot ACF dan PACF Deret *Noise* Pemodelan Produktivitas Apel dan Kelembaban

**Tabel 4.18** Pengujian Parameter Model Fungsi Transfer Kelembaban dan Produktivitas Apel

Model	Parameter	Estimasi	SE	t-value	P-Value
(b=[3],r=0,s=[8]) (Q=1,S=4)	$\Theta_4$	0,57	0,19	2,92	0,0082
	$\omega_0$	0,25	0,14	1,82	0,0828
	$\omega_1$	-0,4	0,17	-2,3	0,0317

Hasil pengujian parameter ditunjukkan pada Tabel 4.18 dapat dilihat bahwa orde (b,r,s) yaitu (b=[3],r=0,s=[8]) signifikan dalam model dan parameter model deret noise ARMA(0,1)<sup>4</sup> signifikan dalam model. Sehingga dapat dikatakan bahwa pemodelan produktivitas apel dengan deret *input* kelembaban dapat digunakan. Berarti produktivitas apel di Kota Batu dipengaruhi kelembaban.

Selanjutnya dilakukan pemeriksaan kelayakan model dengan pengujian asumsi *white noise* dan residual model berdistribusi normal. Hasilnya terdapat pada Lampiran 12, dimana residual telah memenuhi asumsi *white noise* dan berdistribusi normal.

### c. Pemodelan dengan Deret Input Curah Hujan

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde  $(b,r,s)$ . Berikut merupakan plot CCF pada deret input curah hujan dan deret output produktivitas apel.

Crosscorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
-12	-22.033217	-0.02020	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-11	-0.725755	-0.00067	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-10	206.721	0.18956	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-9	286.831	0.26302	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-8	-9.206434	-0.0044	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-7	-187.489	-0.17192	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-6	-311.513	-0.28565	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-5	-335.284	-0.30745	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-4	-50.791308	-0.04657	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-3	126.520	0.11602	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-2	128.098	0.11746	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-1	-90.217603	-0.08273	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
0	39.169291	0.03592	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
1	145.470	0.13339	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
2	203.834	0.18691	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
3	379.209	0.34773	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
4	-23.540454	-0.02159	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
5	-137.949	-0.12650	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
6	-219.075	-0.20089	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
7	-172.831	-0.15848	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
8	49.984805	0.04584	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
9	111.362	0.10212	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
10	165.042	0.15134	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
11	78.982322	0.07243	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
12	35.078535	0.03217	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.

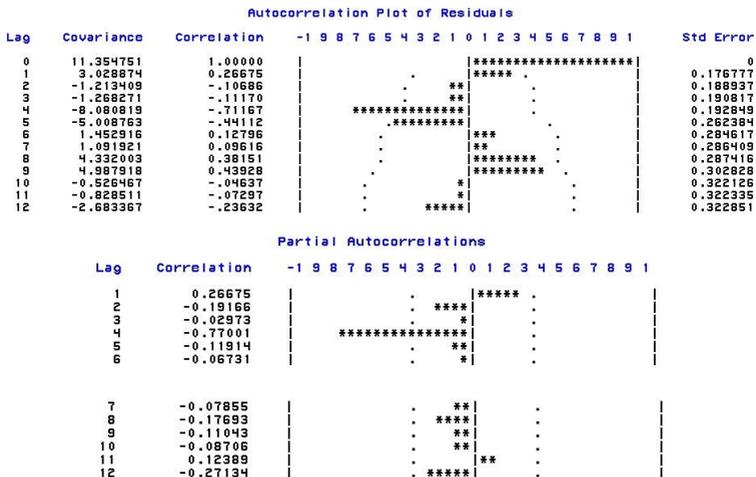
Gambar 4.43 CCF Produktivitas Apel dan Curah Hujan

Plot CCF pada Gambar 4.43 diperoleh kemungkinan nilai orde  $(b,r,s)$  yaitu  $(b=[3],r=0,s=0)$ . Selanjutnya dilakukan pemodelan ARMA terhadap deret *noise*. Berikut merupakan plot ACF dan PACF deret *noise* pada Gambar 4.44.

Model ARMA yang sesuai adalah  $ARMA(1,1)^4$  berdasarkan plot ACF dan PACF pada Gambar 4.44. Selanjutnya dilakukan pemodelan fungsi transfer antara model deret noise  $ARMA(1,1)^4$  dengan orde  $(b,r,s)$  yaitu  $(b=[3],r=0,s=0)$ . Berikut merupakan pengujian parameter model disajikan pada Tabel 4.19.

Berdasarkan Tabel 4.19 dapat dilihat bahwa parameter orde  $(b,r,s)$  yaitu  $(b=[3],r=0,s=0)$  dan model deret noise  $ARMA(1,1)^4$  signifikan dalam model. Sehingga dapat dikatakan bahwa pemodelan produktivitas apel dengan deret *input* curah

hujan dapat digunakan. Berarti produktivitas apel di Kota Batu dipengaruhi curah hujan.



**Gambar 4.44** Plot ACF dan PACF Deret *Noise* Pemodelan Produktivitas Apel dan Curah Hujan

**Tabel 4.19** Pengujian Parameter Model Fungsi Transfer Curah Hujan dan Produktivitas Apel

Model	Parameter	Estimasi	SE	t-value	P-Value
(b=[3],r=0,s=0)	$\Theta_4$	0,53	0,21	2,56	0,016
	$\Phi_4$	-0,58	0,19	-3,05	0,0049
(P=1,Q=1,S=4)	$\omega_0$	0,005	0,001	3,83	0,0006

Selanjutnya dilakukan pemeriksaan kelayakan model dengan pengujian asumsi *white noise* dan residual model berdistribusi normal. Hasilnya terdapat pada Lampiran 13, dimana residual memenuhi asumsi *white noise* dan berdistribusi normal.

## E. Pemodelan Fungsi Transfer pada Produktivitas Jeruk

Pemodelan fungsi transfer produktivitas jeruk dilakukan terhadap beberapa deret input yaitu suhu rata-rata, kelembaban, dan curah hujan.

### a. Pemodelan dengan Deret Input Suhu Rata-rata

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde  $(b,r,s)$ . Berikut merupakan plot CCF pada deret input suhu rata-rata dan deret output produktivitas jeruk.

Crosscorrelations			
Lag	Covariance	Correlation	-1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1
-12	-7.015573	-.18003	. . . . .   . . . . .
-11	0.699916	0.01794	. . . . .   . . . . .
-10	3.342671	0.08578	. . . . .   . . . . .
-9	6.866874	0.17622	. . . . .   . . . . .
-8	-8.154865	-.20927	. . . . .   . . . . .
-7	-0.644844	-.01655	. . . . .   . . . . .
-6	5.257669	0.13492	. . . . .   . . . . .
-5	2.401995	0.06164	. . . . .   . . . . .
-4	-8.126525	-.20854	. . . . .   . . . . .
-3	-1.774953	-.04555	. . . . .   . . . . .
-2	5.377931	0.13800	. . . . .   . . . . .
-1	4.800535	0.12319	. . . . .   . . . . .
0	-9.719454	-.24942	. . . . .   . . . . .
1	-0.770655	-.01978	. . . . .   . . . . .
2	5.613184	0.14404	. . . . .   . . . . .
3	5.963308	0.15303	. . . . .   . . . . .
4	-12.013128	-.30828	. . . . .   . . . . .
5	0.800169	0.02053	. . . . .   . . . . .
6	6.452325	0.16558	. . . . .   . . . . .
7	3.612955	0.09271	. . . . .   . . . . .
8	-10.988890	-.28199	. . . . .   . . . . .
9	-1.545563	-.03966	. . . . .   . . . . .
10	10.427147	0.26758	. . . . .   . . . . .
11	1.923279	0.04935	. . . . .   . . . . .
12	-9.566065	-.24548	. . . . .   . . . . .

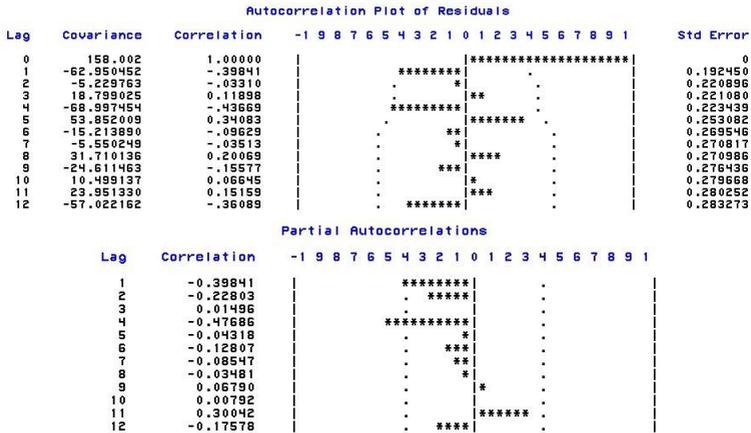
**Gambar 4.45** CCF Produktivitas Jeruk dan Suhu Rata-rata

Diperoleh kemungkinan nilai orde  $(b,r,s)$  yaitu  $(b=[4],r=0,s=[4])$  berdasarkan plot CCF pada Gambar 4.45. Selanjutnya dilakukan pemodelan ARMA terhadap deret *noise*. Berikut merupakan plot ACF dan PACF deret *noise* pada Gambar 4.46.

Berdasarkan plot ACF dan PACF pada Gambar 4.46 maka model ARMA yang sesuai adalah  $ARMA(1,0)^4$ . Selanjutnya dilakukan pemodelan fungsi transfer antara model deret *noise*  $ARMA(1,0)^4$  dengan orde  $(b,r,s)$  yaitu  $(b=[4],r=0,s=[4])$ . Berikut merupakan pengujian parameter model disajikan pada Tabel 4.20.

Orde  $(b,r,s)$  yaitu  $(b=[4],r=0,s=[4])$  dan parameter model deret *noise* signifikan dalam model  $ARMA(1,0)^4$  berdasarkan hasil pengujian parameter pada Tabel 4.20. Sehingga dapat dikatakan bahwa pemodelan produktivitas jeruk dengan deret

*input* suhu rata-rata dapat digunakan. Berarti produktivitas jeruk di Kota Batu dipengaruhi suhu rata-rata.



**Gambar 4.46** Plot ACF dan PACF Deret *Noise* Pemodelan Produktivitas Jeruk dan Suhu Rata-rata

**Tabel 4.20** Pengujian Parameter Model Fungsi Transfer Suhu dan Produktivitas Jeruk

Model	Parameter	Estimasi	SE	t-value	P-Value
(b=[4],r=0,s=[4]) (P=1,S=4)	$\Phi_4$	-0,56	0,18	-3,16	0,0042
	$\omega_0$	-4,2	1,99	-2,11	0,0458
	$\omega_1$	9,06	3,09	2,93	0,0073

Selanjutnya dilakukan pemeriksaan kelayakan model dengan pengujian asumsi *white noise* dan residual model berdistribusi normal. Hasilnya terdapat pada Lampiran 14, dimana residual telah memenuhi asumsi *white noise* dan berdistribusi normal.

### b. Pemodelan dengan Deret Input Kelembaban

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde ( $b,r,s$ ).

Berikut merupakan plot CCF pada deret input kelembaban dan deret output produktivitas jeruk.

Crosscorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
-12	2.996456	0.03053	.	.	.	.	.	.	.	.	.	.	*	.	.	.	.	.	.	.	.	.	.	.
-11	-7.796079	-.07942	.	.	.	.	.	.	.	.	.	.	**	.	.	.	.	.	.	.	.	.	.	.
-10	-8.898587	-.09065	.	.	.	.	.	.	.	.	.	.	**	.	.	.	.	.	.	.	.	.	.	.
-9	10.275788	0.10468	.	.	.	.	.	.	.	.	.	.	.	**	.	.	.	.	.	.	.	.	.	.
-8	-10.762294	-.10964	.	.	.	.	.	.	.	.	.	.	.	**	.	.	.	.	.	.	.	.	.	.
-7	9.792622	0.09976	.	.	.	.	.	.	.	.	.	.	.	.	**	.	.	.	.	.	.	.	.	.
-6	-7.128793	-.07262	.	.	.	.	.	.	.	.	.	.	.	*	.	.	.	.	.	.	.	.	.	.
-5	1.866214	0.01901	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-4	-3.372108	-.03435	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-3	-7.344511	-.07482	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-2	28.727276	0.29265	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-1	-22.863794	-.23292	.	.	.	.	.	.	.	.	.	.	.	*****	*****	.	.	.	.	.	.	.	.	.
0	-6.625480	-.06750	.	.	.	.	.	.	.	.	.	.	.	*	.	.	.	.	.	.	.	.	.	.
1	13.327103	0.13577	.	.	.	.	.	.	.	.	.	.	.	.	***	.	.	.	.	.	.	.	.	.
2	4.229062	0.04308	.	.	.	.	.	.	.	.	.	.	.	.	*	.	.	.	.	.	.	.	.	.
3	-3.462958	-.03528	.	.	.	.	.	.	.	.	.	.	.	.	*	.	.	.	.	.	.	.	.	.
4	1.496103	0.01524	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
5	-6.213093	-.06329	.	.	.	.	.	.	.	.	.	.	.	.	*	.	.	.	.	.	.	.	.	.
6	14.699346	0.14975	.	.	.	.	.	.	.	.	.	.	.	.	.	***	.	.	.	.	.	.	.	.
7	-3.177291	-.03237	.	.	.	.	.	.	.	.	.	.	.	.	.	*	.	.	.	.	.	.	.	.
8	-15.012313	-.15293	.	.	.	.	.	.	.	.	.	.	.	.	.	***	.	.	.	.	.	.	.	.
9	1.020289	0.01039	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
10	4.169779	0.04248	.	.	.	.	.	.	.	.	.	.	.	.	.	*	.	.	.	.	.	.	.	.
11	15.667278	0.15961	.	.	.	.	.	.	.	.	.	.	.	.	.	***	.	.	.	.	.	.	.	.
12	-12.243790	-.12473	.	.	.	.	.	.	.	.	.	.	.	.	.	**	.	.	.	.	.	.	.	.

**Gambar 4.47** CCF Produktivitas Jeruk dan Kelembaban

Berdasarkan plot CCF pada Gambar 4.47 dapat dilihat bahwa tidak ada *lag* yang signifikan, sehingga dapat dikatakan bahwa tidak ada pengaruh antara produktivitas jeruk dengan kelembaban. Oleh karena itu, tidak dilakukan pemodelan fungsi transfer antara produktivitas jeruk dengan deret *input* kelembaban.

### c. Pemodelan dengan Deret Input Curah Hujan

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde ( $b, r, s$ ). Berikut merupakan plot CCF pada deret input curah hujan dan deret output produktivitas jeruk.

Plot CCF pada Gambar 4.48 menunjukkan bahwa tidak ada *lag* yang signifikan, sehingga dapat dikatakan bahwa tidak ada pengaruh antara produktivitas jeruk dengan curah hujan. Oleh karena itu, tidak dilakukan pemodelan fungsi transfer antara produktivitas jeruk dengan deret *input* curah hujan.

Crosscorrelations																							
Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
-12	2.996456	0.03053											*										
-11	-7.796079	-0.07942										**											
-10	-8.898587	-0.09065										**											
-9	10.275788	0.10468											**										
-8	-10.762294	-0.10964											**										
-7	9.792622	0.09976											**										
-6	-7.128793	-0.07262										*											
-5	1.866214	0.01901																					
-4	-3.372108	-0.03435											*										
-3	-7.344511	-0.07482										*											
-2	28.727276	0.29265											*										
-1	-22.863794	-0.23292											*****										
0	-6.625480	-0.06750											*										
1	13.327103	0.13577											*										
2	4.229062	0.04308											*										
3	-3.462958	-0.03528											*										
4	1.496103	0.01524											*										
5	-6.213093	-0.06329											*										
6	14.699346	0.14975											*										
7	-3.177291	-0.03237											*										
8	-15.012313	-0.15293											***										
9	1.020299	0.01039											*										
10	4.169779	0.04248											*										
11	15.667278	0.15961											*										
12	-12.243790	-0.12473											**										

Gambar 4.48 CCF Produktivitas Jeruk dan Curah Hujan

## F. Pemodelan Fungsi Transfer pada Produktivitas Alpukat

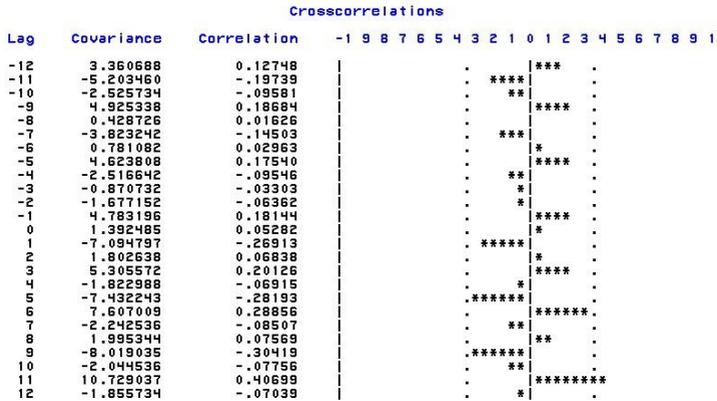
Pemodelan fungsi transfer produktivitas alpukat dilakukan terhadap beberapa deret input yaitu suhu rata-rata, kelembaban, dan curah hujan.

### a. Pemodelan dengan Deret Input Suhu Rata-rata

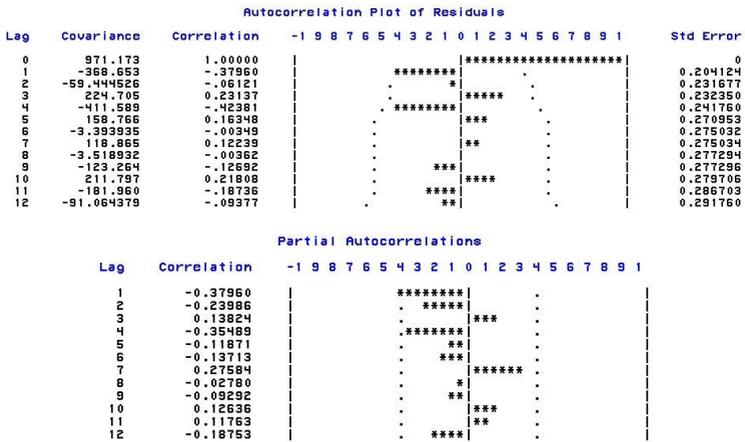
Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde ( $b, r, s$ ). Berikut merupakan plot CCF pada deret input suhu rata-rata dan deret output produktivitas alpukat.

Plot CCF pada Gambar 4.49 diperoleh kemungkinan nilai orde ( $b, r, s$ ) yaitu ( $b=[6], r=0, s=[5]$ ). Selanjutnya dilakukan pemodelan ARMA terhadap deret *noise*. Berikut merupakan plot ACF dan PACF deret *noise* pada Gambar 4.50.

Plot ACF dan PACF pada Gambar 4.50 diperoleh model ARMA yang sesuai adalah ARMA(0,1). Selanjutnya dilakukan pemodelan fungsi transfer antara model deret noise ARMA(0,1) dengan orde ( $b, r, s$ ) yaitu ( $b=[6], r=0, s=[5]$ ). Berikut merupakan pengujian parameter model disajikan pada Tabel 4.21.



Gambar 4.49 CCF Produktivitas Alpakat dan Suhu Rata-rata



Gambar 4.50 Plot ACF dan PACF Deret Noise Pemodelan Produktivitas Alpakat dan Suhu Rata-rata

Tabel 4.21 Pengujian Parameter Model Fungsi Transfer Suhu dan Produktivitas Alpakat

Model	Parameter	Estimasi	SE	t-value	P-Value
(b=[6],r=0,s=[5]) (q=1)	$\phi_1$	-0,46	0,2	-2,27	0,0341
	$\omega_0$	9,4	4,44	2,12	0,0466
	$\omega_1$	-18,53	7,23	-2,56	0,0182

Hasil pengujian parameter pada Tabel 4.21 dapat dilihat bahwa orde  $(b,r,s)$  yaitu  $(b=[6],r=0,s=[5])$  dan parameter model deret noise ARMA(0,1) signifikan dalam model. Sehingga dapat dikatakan bahwa pemodelan produktivitas alpukat dengan deret *input* suhu rata-rata dapat digunakan. Berarti produktivitas alpukat di Kota Batu dipengaruhi suhu rata-rata.

Selanjutnya dilakukan pemeriksaan kelayakan model dengan pengujian asumsi *white noise* dan residual model berdistribusi normal. Hasilnya terdapat pada Lampiran 15, dimana residual telah memenuhi asumsi *white noise* dan berdistribusi normal.

### b. Pemodelan dengan Deret Input Kelembaban

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde  $(b,r,s)$ . Berikut merupakan plot CCF pada deret input kelembaban dan deret output produktivitas alpukat pada Gambar 4.51.

Crosscorrelations			
Lag	Covariance	Correlation	-1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1
-12	-26.451566	-.23633	. . . . .
-11	14.830340	0.13250	. . . . .
-10	11.276527	0.10075	. . . . .
-9	-7.725555	-.08902	. . . . .
-8	7.296355	0.06519	. . . . .
-7	8.848775	0.07906	. . . . .
-6	-24.012331	-.21454	. . . . .
-5	16.726501	0.14944	. . . . .
-4	-20.255431	-.19097	. . . . .
-3	35.951616	0.32121	. . . . .
-2	-6.973652	-.06231	. . . . .
-1	-26.155704	-.23369	. . . . .
0	12.783765	0.11422	. . . . .
1	-0.870373	-.00778	. . . . .
2	-11.522029	-.10294	. . . . .
3	42.230477	0.37731	. . . . .
4	-33.633244	-.30050	. . . . .
5	-24.209535	-.21630	. . . . .
6	13.955087	0.12468	. . . . .
7	25.911104	0.23150	. . . . .
8	9.698898	0.08564	. . . . .
9	-26.106598	-.23325	. . . . .
10	3.476559	0.03106	. . . . .
11	11.886234	0.10620	. . . . .
12	-20.753802	-.18543	. . . . .

Gambar 4.51 CCF Produktivitas Alpukat dan Kelembaban

Berdasarkan plot CCF pada Gambar 4.51 diperoleh kemungkinan nilai orde  $(b,r,s)$  yaitu  $(b=[3],r=0,s=1)$ . Selanjutnya dilakukan pemodelan ARMA terhadap deret *noise*. Berikut merupakan plot ACF dan PACF deret *noise* pada Gambar 4.52.



Selanjutnya dilakukan pemeriksaan kelayakan model dengan pengujian asumsi *white noise* dan residual model berdistribusi normal. Hasilnya terdapat pada Lampiran 16, dimana residual telah memenuhi asumsi *white noise* dan berdistribusi normal.

### c. Pemodelan dengan Deret Input Curah Hujan

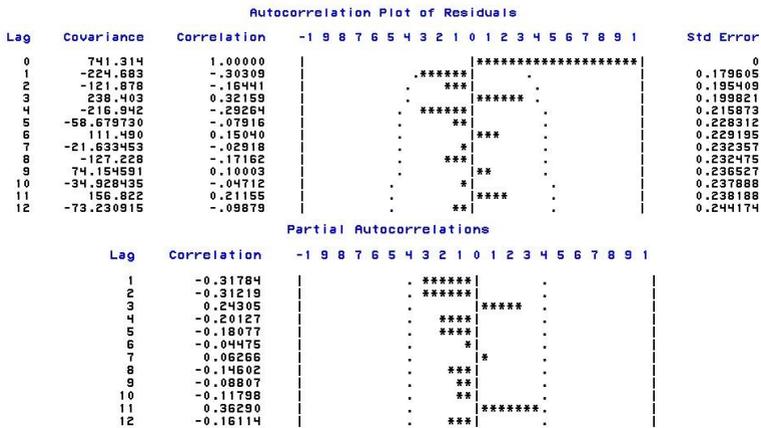
Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde  $(b,r,s)$ . Berikut merupakan plot CCF pada deret input curah hujan dan deret output produktivitas alpukat.

Crosscorrelations																								
Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
-12	214.844	0.04480	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-11	-903.454	-0.18841	.	.	.	.	.	.	.	.	.	.	.	****	.	.	.	.	.	.	.	.	.	.
-10	95.330456	0.02001	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-9	168.977	0.03524	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-8	-826.537	-0.17237	.	.	.	.	.	.	***	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-7	1489.168	0.31055	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-6	374.839	0.07818	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-5	90.23813	0.01882	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-4	510.493	0.10646	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-3	374.129	0.07802	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-2	-282.653	-0.05894	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-1	-1938.134	-0.40419	.	.	.	.	.	.	.	.	.	.	.	*****	.	.	.	.	.	.	.	.	.	.
0	470.750	0.09817	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
1	-225.450	-0.04702	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
2	154.318	0.03218	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
3	1049.332	0.21884	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
4	-1588.043	-0.33117	.	.	.	.	.	.	.	.	.	.	.	*****	.	.	.	.	.	.	.	.	.	.
5	54.037869	0.01127	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
6	279.272	0.05824	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
7	2046.495	0.42578	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
8	410.352	0.08557	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
9	-1013.387	-0.21146	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
10	-645.359	-0.13458	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
11	-1030.582	-0.22743	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
12	410.545	0.08561	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.

Gambar 4.53 CCF Produktivitas Alpukat dan Curah Hujan

Nilai orde  $(b,r,s)$  yaitu  $(b=[4],r=0,s=0)$  berdasarkan plot CCF pada Gambar 4.53. Selanjutnya dilakukan pemodelan ARMA terhadap deret *noise*. Berikut merupakan plot ACF dan PACF deret *noise* pada Gambar 4.54.

Berdasarkan plot ACF dan PACF pada Gambar 4.54 maka model ARMA yang sesuai adalah  $ARMA(2,0)(0,1)^4$ . Selanjutnya dilakukan pemodelan fungsi transfer antara model deret *noise*  $ARMA(2,0)(0,1)^4$  dengan orde  $(b,r,s)$  yaitu  $(b=[4],r=0,s=0)$ . Berikut merupakan pengujian parameter model disajikan pada Tabel 4.23.



**Gambar 4.54** Plot ACF dan PACF Deret *Noise* Pemodelan Produktivitas Alpukat dan Curah Hujan

**Tabel 4.23** Pengujian Parameter Model Fungsi Transfer Curah Hujan dan Produktivitas Alpukat

Model	Parameter	Estimasi	SE	t-value	P-Value
(b=[4],r=0,s=0) (p=2,Q=1,S=4)	$\Theta_4$	0,82	0,15	5,5	<0,0001
	$\varphi_1$	-0,66	0,21	-3,2	0,0035
	$\varphi_2$	-0,45	0,2	-2,23	0,0346
	$\omega_0$	-0,03	0,01	-2,45	0,0211

Berdasarkan Tabel 4.23 dapat dilihat bahwa orde (b,r,s) yaitu (b=[4],r=0,s=0) dan parameter model deret noise ARMA(2,0)(0,1)<sup>4</sup> signifikan dalam model. Sehingga dapat dikatakan bahwa pemodelan produktivitas alpukat dengan deret *input* curah hujan dapat digunakan. Berarti produktivitas alpukat di Kota Batu dipengaruhi curah hujan.

Selanjutnya dilakukan pemeriksaan kelayakan model dengan pengujian asumsi *white noise* dan residual model berdistribusi normal. Hasilnya terdapat pada Lampiran 17, dimana residual memenuhi asumsi *white noise* berdistribusi normal.

## G. Pemodelan Fungsi Transfer pada Produktivitas Jambu Biji

Pemodelan fungsi transfer produktivitas jambu biji dilakukan terhadap beberapa deret input yaitu suhu rata-rata, kelembaban, dan curah hujan.

### a. Pemodelan dengan Deret Input Suhu Rata-rata

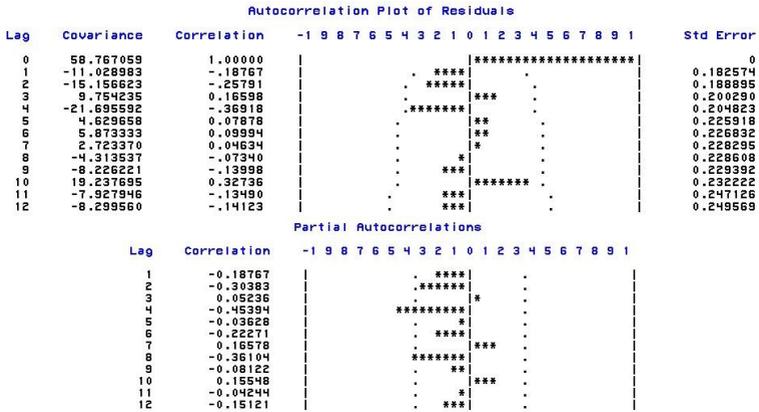
Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde  $(b,r,s)$ . Berikut merupakan plot CCF pada deret input suhu rata-rata dan deret output produktivitas jambu biji.

Crosscorrelations			
Lag	Covariance	Correlation	-1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1
-12	3.373408	0.23973	. . . . .   ***** .
-11	-3.395414	-.24129	. . . . .   ***** .
-10	-0.538596	-.03827	. . . . .   ***** .
-9	2.440201	0.17341	. . . . .   ***** .
-8	2.159778	0.15633	. . . . .   ***** .
-7	-2.809257	-.19964	. . . . .   ***** .
-6	-0.608747	-.04326	. . . . .   ***** .
-5	2.627278	0.18671	. . . . .   ***** .
-4	0.890941	0.06331	. . . . .   ***** .
-3	-3.200366	-.22743	. . . . .   ***** .
-2	0.744419	0.05290	. . . . .   ***** .
-1	2.112576	0.15013	. . . . .   ***** .
0	0.935707	0.06650	. . . . .   ***** .
1	-5.605947	-.39838	. . . . .   ***** .
2	1.840961	0.13083	. . . . .   ***** .
3	3.977147	0.28263	. . . . .   ***** .
4	0.911480	0.06477	. . . . .   ***** .
5	-4.592031	-.32633	. . . . .   ***** .
6	1.373438	0.09760	. . . . .   ***** .
7	1.837655	0.13059	. . . . .   ***** .
8	0.094440	0.00671	. . . . .   ***** .
9	-4.062966	-.28873	. . . . .   ***** .
10	-0.534322	-.03797	. . . . .   ***** .
11	4.332247	0.30787	. . . . .   ***** .
12	-0.544617	-.03870	. . . . .   ***** .

Gambar 4.55 CCF Produktivitas Jambu Biji dan Suhu Rata-rata

Berdasarkan Gambar 4.55 diperoleh kemungkinan nilai orde  $(b,r,s)$  yaitu  $(b=1,r=0,s=[4])$ . Selanjutnya dilakukan pemodelan ARMA terhadap deret *noise*. Berikut merupakan plot ACF dan PACF deret *noise* pada Gambar 4.56.

Plot ACF dan PACF pada Gambar 4.56 diperoleh model ARMA yang sesuai adalah  $ARMA(0,1)^4$ . Selanjutnya dilakukan pemodelan fungsi transfer antara model deret *noise*  $ARMA(0,1)^4$  dengan orde  $(b,r,s)$  yaitu  $(b=1,r=0,s=[4])$ . Berikut merupakan pengujian parameter model disajikan pada Tabel 4.24.



Gambar 4.56 Plot ACF dan PACF Deret Noise Pemodelan Produktivitas Jambu Biji dan Suhu Rata-rata

Tabel 4.24 Pengujian Parameter Model Fungsi Transfer Suhu dan Produktivitas Jambu Biji

Model	Parameter	Estimasi	SE	t-value	P-Value
(b=1,r=0,s=[4]) (Q=1,S=4)	$\Theta_4$	0,98	0,1	9,92	<0,0001
	$\omega_0$	-2,01	1,1	-1,83	0,0791
	$\omega_1$	1,33	1,14	1,16	0,2544

Hasil pengujian parameter ditunjukkan pada Tabel 4.24 diperoleh hasil bahwa orde (b,r,s) yaitu (b=1,r=0,s=[4]) tidak signifikan dalam model, namun parameter model deret noise ARMA(0,1)<sup>4</sup> signifikan dalam model. Sehingga dapat dikatakan bahwa pemodelan produktivitas jambu biji dengan deret *input* suhu rata-rata tidak dapat digunakan. Berarti produktivitas jambu biji di Kota Batu tidak dipengaruhi suhu rata-rata.

**b. Pemodelan dengan Deret Input Kelembaban**

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde (b,r,s). Berikut merupakan plot CCF pada deret *input* kelembaban dan deret *output* produktivitas jambu biji.

Crosscorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
-12	-4.516077	-.10924	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-11	11.918902	0.28831	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-10	-6.571726	-.15896	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-9	-8.471721	-.20492	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-8	3.733392	0.09045	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-7	4.123156	0.08973	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-6	-2.016669	-.04878	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-5	-3.681093	-.08904	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-4	-4.051818	-.09801	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-3	5.714203	0.13822	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-2	-5.267171	-.12741	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-1	9.615244	0.23258	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
0	1.233657	0.02984	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
1	-14.522365	-.35128	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
2	3.688752	0.08923	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
3	19.708545	0.47673	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
4	-3.357299	-.08121	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
5	-12.073549	-.29205	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
6	-0.913909	-.02211	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
7	8.325361	0.20138	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
8	2.134910	0.05164	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
9	-4.986758	-.12062	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
10	6.089583	0.14730	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
11	-1.967956	-.04760	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
12	-6.347118	-.15353	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.

Gambar 4.57 CCF Produktivitas Jambu Biji dan Kelembaban

Plot CCF pada Gambar 4.57 diperoleh kemungkinan nilai orde (b,r,s) yaitu (b=[3],r=0,s=0). Selanjutnya dilakukan pemodelan ARMA terhadap deret noise. Berikut merupakan plot ACF dan PACF deret noise pada Gambar 4.58.

Autocorrelation Plot of Residuals

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error
0	52.774509	1.00000	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0
1	-11.887797	-.22545	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.176777
2	-10.016010	-.18979	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.185544
3	5.499295	0.10420	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.191515
4	-17.939997	-.33994	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.193278
5	5.319354	0.10081	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.211137
6	5.626856	0.10662	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.212636
7	2.601221	0.04929	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.214300
8	-4.223195	-.08002	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.214654
9	-5.500281	-.12317	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.215584
10	9.238657	0.17506	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.217772
11	-6.035792	-.11437	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.222126
12	-3.485724	-.06605	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	0.223959

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1		
1	-0.22545	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
2	-0.25350	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
3	-0.00741	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
4	-0.40588	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
5	-0.10016	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
6	-0.10234	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
7	0.09439	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
8	-0.20127	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
9	-0.17575	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
10	0.06998	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
11	-0.08438	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
12	-0.21050	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.

Gambar 4.58 Plot ACF dan PACF Deret Noise Pemodelan Produktivitas Jambu Biji dan Kelembaban

Diperoleh model ARMA yang sesuai adalah ARMA(0,1)<sup>4</sup> berdasarkan plot ACF dan PACF pada Gambar 4.58. Selanjutnya dilakukan pemodelan fungsi transfer antara model deret noise

ARMA(0,1)<sup>4</sup> dengan orde (b,r,s) yaitu (b=[3],r=0,s=0). Berikut merupakan pengujian parameter model disajikan pada Tabel 4.25.

**Tabel 4.25** Pengujian Parameter Model Fungsi Transfer Kelembaban dan Produktivitas Jambu Biji

Model	Parameter	Estimasi	SE	t-value	P-Value
(b=[3],r=0,s=0) (Q=1,S=4)	$\Theta_4$	0,95	0,08	11,86	<0,0001
	$\omega_0$	0,59	0,22	2,73	0,0104

Pengujian parameter pada Tabel 4.25 dapat dilihat bahwa orde (b,r,s) yaitu (b=[3],r=0,s=0) dan parameter model deret noise ARMA(0,1)<sup>4</sup> signifikan dalam model. Sehingga dapat dikatakan bahwa pemodelan produktivitas jambu biji dengan deret *input* kelembaban dapat digunakan. Berarti produktivitas jambu biji di Kota Batu dipengaruhi kelembaban.

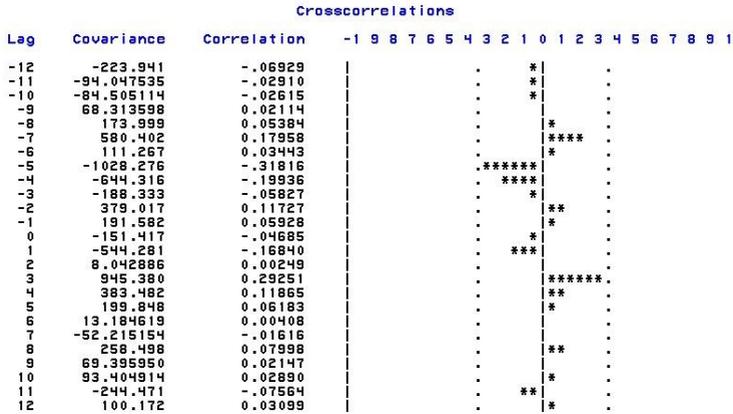
Selanjutnya dilakukan pemeriksaan kelayakan model dengan pengujian asumsi *white noise* dan residual model berdistribusi normal. Hasilnya terdapat pada Lampiran 19, dimana residual memenuhi asumsi *white noise* namun tidak berdistribusi normal.

### c. Pemodelan dengan Deret Input Curah Hujan

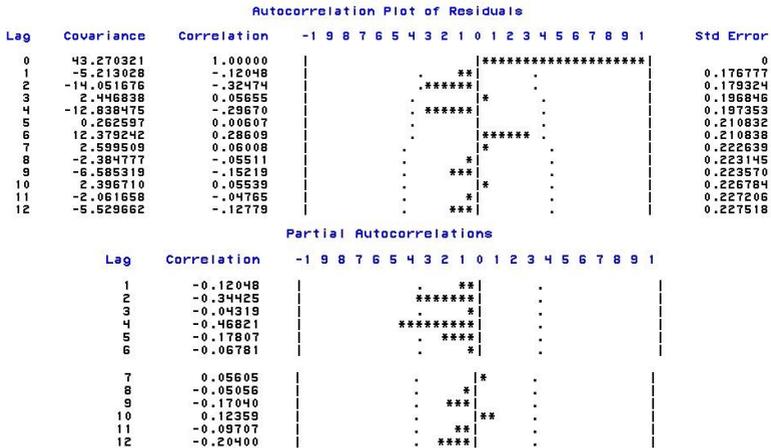
Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde (b,r,s). Berikut merupakan plot CCF pada deret input curah hujan dan deret output produktivitas jambu biji pada Gambar 4.59.

Berdasarkan plot CCF Gambar 4.59 diperoleh kemungkinan nilai orde (b,r,s) yaitu (b=[3],r=0,s=0). Selanjutnya dilakukan pemodelan ARMA terhadap deret *noise*. Berikut merupakan plot ACF dan PACF deret *noise* pada Gambar 4.60.

Berdasarkan plot ACF dan PACF pada Gambar 4.60 maka model ARMA yang sesuai adalah ARMA([2],0)(1,0)<sup>4</sup>. Selanjutnya dilakukan pemodelan fungsi transfer antara model deret noise ARMA([2],0)(1,0)<sup>4</sup> dengan orde (b,r,s) yaitu (b=[3],r=0,s=0). Berikut merupakan pengujian parameter model disajikan pada Tabel 4.26.



Gambar 4.59 CCF Produktivitas Jambu Biji dan Curah Hujan



Gambar 4.60 Plot ACF dan PACF Deret Noise Pemodelan Produktivitas Jambu Biji dan Curah Hujan

Tabel 4.26 Pengujian Parameter Model Fungsi Transfer Curah Hujan dan Produktivitas Jambu Biji

Model	Parameter	Estimasi	SE	t-value	P-Value
(b=[3],r=0,s=0) (p=[2],P=1,S=4)	$\phi_2$	-0,49	0,18	-2,79	0,0091
	$\Phi_4$	-0,53	0,18	-3,02	0,0052
	$\omega_0$	0,01	0,003	4,24	0,0002

Tabel 4.26 menunjukkan pengujian parameter yang diperoleh hasil bahwa orde  $(b,r,s)$  yaitu  $(b=[3],r=0,s=0)$  dan parameter model deret noise  $ARMA([2],0)(1,0)^4$  signifikan dalam model. Sehingga dapat dikatakan bahwa pemodelan produktivitas jambu biji dengan deret *input* curah hujan dapat digunakan. Berarti produktivitas jambu biji di Kota Batu dipengaruhi curah hujan.

Selanjutnya dilakukan pemeriksaan kelayakan model dengan pengujian asumsi *white noise* dan residual model berdistribusi normal. Hasilnya terdapat pada Lampiran 20, dimana residual memenuhi asumsi *white noise* dan berdistribusi normal.

## H. Pemodelan Fungsi Transfer pada Produktivitas Pisang

Pemodelan fungsi transfer produktivitas pisang dilakukan terhadap beberapa deret input yaitu suhu rata-rata, kelembaban, dan curah hujan.

### a. Pemodelan dengan Deret Input Suhu Rata-rata

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde  $(b,r,s)$ . Berikut merupakan plot CCF pada deret input suhu rata-rata dan deret output produktivitas pisang.

Crosscorrelations																									
Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1		
-12	-8.739518	-.22032																							
-11	-0.358161	-.00903																							
-10	0.333770	0.00841																							
-9	3.451609	0.08701																							
-8	-6.648667	-.16761																							
-7	3.000833	0.07565																							
-6	4.541239	0.11448																							
-5	0.816710	0.02059																							
-4	-7.202650	-.18158																							
-3	-0.985399	-.02449																							
-2	3.872497	0.09763																							
-1	1.803772	0.04547																							
0	-9.715865	-.24494																							
1	3.618656	0.09123																							
2	1.775294	0.04475																							
3	1.035201	0.02610																							
4	-8.776094	-.22124																							
5	4.001388	0.10087																							
6	2.326959	0.05866																							
7	2.740118	0.06909																							
8	-5.849481	-.14747																							
9	-0.996167	-.02511																							
10	8.722160	0.21989																							
11	-1.569114	-.03956																							
12	-5.660276	-.14270																							

Gambar 4.61 CCF Produktivitas Pisang dan Suhu Rata-rata

Gambar 4.61 merupakan plot CCF yang menunjukkan hasil bahwa tidak ada *lag* yang signifikan, sehingga dapat dikatakan bahwa tidak ada pengaruh antara produktivitas pisang dengan suhu rata-rata. Oleh karena itu, tidak dilakukan pemodelan fungsi transfer antara produktivitas pisang dengan deret *input* suhu rata-rata.

### b. Pemodelan dengan Deret Input Kelembaban

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-whitening*. CCF digunakan untuk menentukan nilai orde ( $b, r, s$ ). Berikut merupakan plot CCF pada deret input kelembaban dan deret output produktivitas pisang pada Gambar 4.62.

Lag	Covariance	Correlation	Crosscorrelations																				
			-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
-12	13.318808	0.12891	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-11	-15.115927	-.14630	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-10	1.534400	0.01485	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-9	21.404967	0.20717	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-8	-21.301578	-.20617	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-7	15.651201	0.18051	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-6	2.719372	0.02632	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-5	-0.920582	-.00891	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-4	-11.097565	-.10741	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-3	-15.200660	-.14712	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-2	15.377014	0.14883	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
-1	-6.088012	-.05892	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
0	-14.556066	-.14088	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
1	17.624868	0.17252	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
2	0.756586	0.00732	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
3	-12.882926	-.12469	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
4	-2.686509	-.02600	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
5	-1.534943	-.01486	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
6	9.310494	0.09011	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
7	-2.882981	-.02790	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
8	-1.656578	-.01603	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
9	4.713342	0.04562	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
10	-6.725556	-.06509	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
11	-1.623707	-.01571	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
12	2.344551	0.02269	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.

Gambar 4.62 CCF Produktivitas Pisang dan Kelembaban

Plot CCF pada Gambar 4.62 dapat dilihat bahwa tidak ada *lag* yang signifikan, sehingga dapat dikatakan bahwa tidak ada pengaruh antara produktivitas pisang dengan kelembaban. Oleh karena itu, tidak dilakukan pemodelan fungsi transfer antara produktivitas pisang dengan deret *input* kelembaban.

### c. Pemodelan dengan Deret Input Curah Hujan

Pembentukan model awal fungsi transfer ialah dengan cara mendapatkan *Crosscorrelation Function* (CCF) antara deret *input* dan deret *output* yang telah mengalami proses *pre-*

*whitening*. CCF digunakan untuk menentukan nilai orde ( $b, r, s$ ). Berikut merupakan plot CCF pada deret input curah hujan dan deret output produktivitas pisang.

Crosscorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1		
-12	749.686	0.09526												**											
-11	-692.312	-.08797											**												
-10	177.733	0.02258																							
-9	150.348	0.01910																							
-8	-63.090483	-.00802																							
-7	2240.220	0.28466												*****											
-6	773.909	0.09834												**											
-5	927.437	0.11785												**											
-4	-811.758	-.10315											**												
-3	-552.973	-.07027											*												
-2	-1184.545	-.15052											***												
-1	-945.473	-.12014											**												
0	-233.874	-.02372											*												
1	-399.070	-.05071											*												
2	-216.909	-.02756											*												
3	-327.683	-.04164											*												
4	-41.238233	-.00524																							
5	183.202	0.02328																							
6	344.614	0.04379												*											
7	285.246	0.03625												*											
8	-300.965	-.03824											*												
9	-333.828	-.04242											*												
10	-430.733	-.05473											*												
11	-395.143	-.05021											*												
12	-179.857	-.02285											*												

**Gambar 4.63** CCF Produktivitas Pisang dan Curah Hujan

Diperoleh hasil bahwa tidak ada *lag* yang signifikan berdasarkan plot CCF pada Gambar 4.63, sehingga dapat dikatakan bahwa tidak ada pengaruh antara produktivitas pisang dengan curah hujan. Oleh karena itu, tidak dilakukan pemodelan fungsi transfer antara produktivitas pisang dengan deret *input* curah hujan.

### I. Pemilihan Model Terbaik pada Metode Fungsi Transfer

Berdasarkan hasil di atas diperoleh model terbaik untuk produktivitas jeruk adalah dengan deret *input* suhu rata-rata, sedangkan produktivitas pisang tidak dapat dimodelkan menggunakan fungsi transfer. Produktivitas apel, alpukat, dan jambu biji memperoleh beberapa model dugaan pada metode fungsi transfer, sehingga perlu dilakukan pemilihan model terbaik. Pemilihan model terbaik ini dengan mempertimbangkan nilai RMSEP dan MAPEP pada data *testing*. Berikut merupakan hasil perhitungan nilai RMSEP dan MAPEP pada Tabel 4.27.

**Tabel 4.27** Pemilihan Model Terbaik Metode Fungsi Transfer

Deret output	Deret input	RMSEP	MAPEP
Produktivitas Apel	Kelembaban	3,73095494	43,179291
	<b>Curah Hujan</b>	<b>2,19349932</b>	<b>27,9984737</b>
Produktivitas Alpukat	Suhu	25,2501432	89,6922859
	Kelembaban	18,3515219	39,7909955
	<b>Curah Hujan</b>	<b>11,9319203</b>	<b>31,9421776</b>
Produktivitas Jambu Biji	Kelembaban	7,53212939	49,9772068
	<b>Curah Hujan</b>	<b>2,57725544</b>	<b>15,1625319</b>

Nilai RMSEP dan MAPEP terkecil dapat dilihat berdasarkan Tabel 4.27. Produktivitas apel, alpukat, dan jambu biji dengan deret *input* curah hujan merupakan model terbaik karena memiliki nilai RMSEP dan MAPEP terkecil. Berikut merupakan model fungsi transfer pada masing-masing produktivitas buah di Kota Batu.

- a. Model fungsi transfer produktivitas apel dengan deret *input* curah hujan dimana orde (b,r,s) yaitu (b=[3],r=0,s=0) dan model deret noise ARMA(1,1)<sup>4</sup> adalah sebagai berikut:

$$(1-B)(1-B^4)Y_{1,t} = (0,004827)(B^3)(1-B)(1-B^4)X_{3,t} + \frac{(1-0,53309B^4)}{(1+0,57901B^4)}a_{1,t}$$

atau

$$Y_{1,t} = Y_{1,t-1} + 0,42099Y_{1,t-4} + 1,5790Y_{1,t-5} + 0,5790Y_{1,t-8} - 0,5790Y_{1,t-9} \\ + 0,004827X_{3,t-3} - 0,004827X_{3,t-4} - 0,004827X_{3,t-7} - 0,004827X_{3,t-8} \\ - 0,53309a_{1,t-4} + a_{1,t}$$

dengan model deret *input*

$$X_{3,t} = X_{3,t-1} + 0,46353X_{3,t-4} + 1,53647X_{3,t-5} + 0,53647X_{3,t-8} \\ + 0,53647X_{3,t-9} - 0,92425\alpha_{3,t-1} + \alpha_{3,t}$$

- b. Model fungsi transfer produktivitas jeruk dengan deret *input* suhu rata-rata dimana orde (b,r,s) yaitu (b=[4],r=0,s=[4]) dan model deret noise ARMA(1,0)<sup>4</sup> adalah sebagai berikut:

$$(1-B)(1-B^4)Y_{2,t} = (-4,1978 - 9,06127B)(B^4)(1-B)(1-B^4)X_{1,t} \\ + \frac{1}{(1+0,56029B^4)} a_{2,t}$$

atau

$$Y_{2,t} = Y_{2,t-1} + 0,4397Y_{2,t-4} + 1,56029Y_{2,t-5} + 0,56029Y_{2,t-8} + 0,56029Y_{2,t-9} \\ - 4,1978X_{1,t-4} - 4,86347X_{1,t-5} + 9,06127X_{1,t-6} + 4,1978X_{1,t-8} \\ + 13,25907X_{1,t-9} + 9,06127X_{1,t-10} + a_{2,t}$$

dengan model deret *input*

$$X_{1,t} = X_{1,t-1} + X_{1,t-4} + X_{1,t-5} - 0,97388\alpha_{1,t-4} + \alpha_{1,t}$$

c. Model fungsi transfer produktivitas alpukat dengan deret *input* curah hujan dimana orde (b,r,s) yaitu (b=[4],r=0,s=0) dan model deret noise ARMA(2,0)(0,1)<sup>4</sup> adalah sebagai berikut:

$$(1-B)(1-B^4)Y_{3,t} = (-0,03339)(B^4)(1-B)(1-B^4)X_{3,t} \\ + \frac{(1-0,81684B^4)}{(1+0,66219B+0,45335B^2)} a_{3,t}$$

atau

$$Y_{3,t} = 0,3378Y_{3,t-1} + 0,20884Y_{3,t-2} + 0,45335Y_{3,t-3} + Y_{3,t-4} + 1,66219Y_{3,t-5} \\ + 1,1154Y_{3,t-6} + 0,45335Y_{3,t-7} - 0,03339X_{3,t-4} - 0,03339X_{3,t-5} \\ - 0,03339X_{3,t-8} - 0,03339X_{3,t-9} - 0,81684a_{3,t-4} + a_{3,t}$$

dengan model deret *input*

$$X_{3,t} = X_{3,t-1} + 0,46353X_{3,t-4} + 1,53647X_{3,t-5} + 0,53647X_{3,t-8} \\ + 0,53647X_{3,t-9} - 0,92425\alpha_{3,t-1} + \alpha_{3,t}$$

d. Model fungsi transfer produktivitas jambu biji dengan deret *input* curah hujan dimana orde (b,r,s) yaitu (b=[3],r=0,s=0) dan model deret noise ARMA([2],0)(1,0)<sup>4</sup> adalah sebagai berikut:

$$(1-B)(1-B^4)Y_{4,t} = (0,01209)(B^3)(1-B)(1-B^4)X_{3,t} \\ + \frac{1}{(1+0,49288B^2)(1+0,53241B^4)} a_{4,t}$$

atau

$$\begin{aligned}
Y_{4,t} = & Y_{4,t-1} - 0,49288Y_{4,t-2} + 0,49288Y_{4,t-3} + 0,46759Y_{4,t-4} + 1,5324Y_{4,t-5} \\
& + 0,23047Y_{4,t-6} + 0,75529Y_{4,t-7} + 0,5324Y_{4,t-8} + 0,5324Y_{4,t-9} \\
& + 0,2624Y_{4,t-10} + 0,2624Y_{4,t-11} + 0,01209X_{3,t-3} - 0,01209X_{3,t-4} \\
& - 0,01209X_{3,t-7} - 0,01209X_{3,t-8} + a_{4,t}
\end{aligned}$$

dengan model deret *input*

$$\begin{aligned}
X_{3,t} = & X_{3,t-1} + 0,46353X_{3,t-4} + 1,53647X_{3,t-5} + 0,53647X_{3,t-8} \\
& + 0,53647X_{3,t-9} - 0,92425\alpha_{3,t-1} + \alpha_{3,t}
\end{aligned}$$

### 4.2.3 Pengujian Linieritas pada Data Produktivitas Lima Buah di Kota Batu

Pengujian linieritas dari data produktivitas lima buah di Kota Batu dilakukan untuk mengetahui jenis dari data. Pengujian linieritas ini dilakukan dengan *White Test* berdasarkan hasil dari model fungsi transfer dan model ARIMA. Berikut merupakan uji linieritas pada produktivitas buah yang disajikan pada Tabel 4.28.

**Tabel 4.28** Uji Linieritas Produktivitas Buah

Variabel	F	P-value
Produktivitas Apel	0,69	0,51
Produktivitas Jeruk	0,57	0,57
Produktivitas Alpukat	1,15	0,33
Produktivitas Jambu Biji	0,83	0,45
Produktivitas Pisang	0,79	0,46

Pengujian linieritas yang disajikan pada Tabel 4.28 diperoleh hasil bahwa semua *P-value* hasil uji *White* yang diperoleh untuk produktivitas buah buah tidak signifikan pada taraf 5%, sehingga dapat disimpulkan bahwa data produktivitas buah berpola linier. Akan tetapi, pada penelitian ini tetap dilakukan pemodelan dengan metode nonlinier yaitu FFNN.

### 4.2.4 Pemodelan Produktivitas Lima Buah di Kota Batu dengan Metode FFNN

Sebelum dilakukan pemodelan FFNN, terlebih dahulu dilakukan *standardized* data. Pemodelan FFNN terhadap

produktivitas apel, jeruk, alpukat, dan jambu biji di Kota Batu dilakukan dengan *input* yang digunakan berdasarkan pemodelan fungsi transfer. Sedangkan input yang digunakan pada pemodelan produktivitas pisang adalah model ARIMA. Pemodelan dengan menggunakan FFNN ini dilakukan dengan replikasi sebanyak 5 kali. Jumlah neuron dalam *hidden layer* yang digunakan dalam pemodelan adalah sebanyak 1-10. Kemudian dipilih jumlah neuron terbaik dilihat dari nilai SSE data *testing* paling rendah.

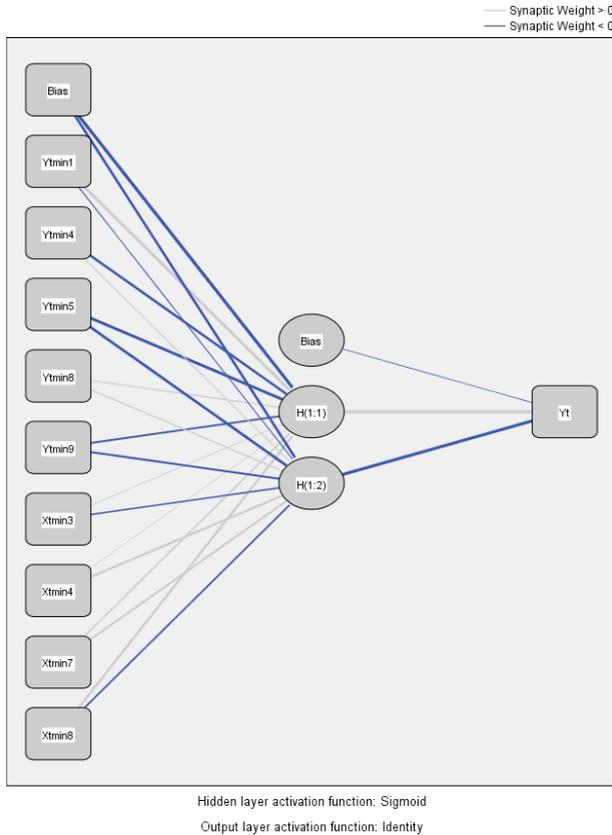
### A. Pemodelan Produktivitas Apel

Pemodelan produktivitas apel menggunakan deret *input*  $Y_{t-1}, Y_{t-4}, Y_{t-5}, Y_{t-8}, Y_{t-9}, X_{t-3}, X_{t-4}, X_{t-7}, X_{t-8}$  dimana  $X$  adalah curah hujan. Berikut merupakan hasil nilai SSE data testing pada pemodelan produktivitas apel yang disajikan pada Tabel 4.29.

**Tabel 4.29** Nilai SSE Pemodelan FFNN pada Produktivitas Apel

Jumlah neuron	SSE data <i>Testing</i>				
	1	2	3	4	5
1	0,041	0,021	0,018	0,033	0,069
2	0,034	0,009	0,073	0,051	0,09
3	0,081	0,053	0,048	0,051	0,064
4	0,048	0,098	0,107	0,038	0,085
5	0,088	0,098	0,052	0,078	0,12
6	0,109	0,091	0,072	0,072	0,032
7	0,124	0,061	0,088	0,014	0,118
8	0,116	0,108	0,041	0,026	0,031
9	0,144	0,016	0,105	0,055	0,116
10	0,09	0,095	0,12	0,13	0,147

Model FFNN terbaik pada produktivitas apel adalah dengan neuron sebanyak 2 pada *hidden layer* dan pada replikasi ke-2 berdasarkan nilai SSE data *testing* yang disajikan pada Tabel 4.29 diperoleh hasil bahwa dengan arsitektur FFNN(9,2,1) pada Gambar 4.64.



**Gambar 4.64** Arsitektur FFNN(9,2,1) Produktivitas Apel

Secara matematis persamaan untuk model FFNN(9,2,1) berdasarkan Gambar 4.64 dapat dituliskan sebagai berikut:

$$\hat{Y}_{1,t}^* = -0,119 + 3,263f_1^h - 1,849f_2^h$$

dengan:

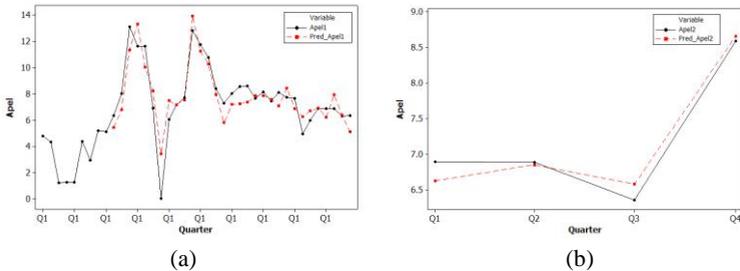
$\hat{Y}_{1,t}^*$  adalah nilai *standardized* dari  $\hat{Y}_{1,t}$

$f_j^h$  adalah fungsi aktivasi untuk *hidden layer* ke- $j$ ,  $j=1,2$

$$f_1^h = (1 + \exp(-(-2,559 + 1,635Y_{1,t-1} - 0,99Y_{1,t-4} - 1,523Y_{1,t-5} + 0,272Y_{1,t-8} - 0,598Y_{1,t-9} + 0,135X_{3,t-3} + 0,062X_{3,t-4} + 0,507X_{3,t-7} + 0,984X_{3,t-8})))^{-1}$$

$$f_2^h = (1 + \exp(-(-0,99 - 0,136Y_{1,t-1} + 0,264Y_{1,t-4} - 1,408Y_{1,t-5} - 0,326Y_{1,t-8} - 0,774Y_{1,t-9} - 0,39X_{3,t-3} + 0,927X_{3,t-4} + 0,813X_{3,t-7} - 0,564X_{3,t-8})))^{-1}$$

Kebaikan model dapat juga dilihat melalui *plot time series* dari perbandingan data asli *training* dan *testing* dengan hasil ramalan. Berikut merupakan *Plot time series* perbandingan data asli dan data hasil ramalan pada produktivitas apel dijelaskan pada Gambar 4.65.



**Gambar 4.65** *Plot Time Series* Perbandingan (a) Data *Training* dan *Fits* (b) Data *Testing* dan Hasil Ramalan Model FFNN Produktivitas Apel

Nilai *fits* untuk data *training* dan ramalan untuk data *testing* menunjukkan hasil yang baik ditunjukkan dengan adanya titik yang berhimpit dari kedua garis pada Gambar 4.65. Nilai ramalan pada data *testing* dan nilai *fits* pada data *training* juga sudah mengikuti pola data.

**B. Pemodelan Produktivitas Jeruk**

Pemodelan produktivitas jeruk menggunakan deret *input*  $Y_{t-1}, Y_{t-4}, Y_{t-5}, Y_{t-8}, Y_{t-9}, X_{t-4}, X_{t-5}, X_{t-6}, X_{t-8}, X_{t-9}, X_{t-10}$  dimana  $X$  adalah suhu. Berikut merupakan hasil nilai SSE data *testing* pada pemodelan produktivitas jeruk yang disajikan pada Tabel 4.30.

Berdasarkan Tabel 4.30 diperoleh hasil bahwa model FFNN terbaik pada produktivitas jeruk adalah dengan neuron sebanyak 6 pada *hidden layer* dan pada replikasi ke-3 yaitu dengan arsitektur FFNN(11,6,1) pada Gambar 4.66.

**Tabel 4.30** Nilai SSE Pemodelan FFNN pada Produktivitas Jeruk

Jumlah neuron	SSE data Testing				
	1	2	3	4	5
1	2,322	2,64	2,123	2,204	2,473
2	2,621	2,325	2,279	2,178	2,893
3	2,258	2,206	1,996	2,183	2,499
4	2,655	2,447	2,367	2,463	2,483
5	2,133	2,341	2,255	2,301	2,126
6	2,391	2,592	1,594	2,573	2,068
7	2,163	2,42	2,557	1,868	2,186
8	2,207	2,619	2,293	2,461	2,368
9	1,974	2,093	2,07	2,258	2,543
10	2,24	2,447	2,403	2,455	2,373

Secara matematis persamaan untuk model FFNN(11,6,1) berdasarkan Gambar 4.66 dapat dituliskan sebagai berikut:

$$\hat{Y}_{2,t}^* = -0,01 + 0,713f_1^h - 0,328f_2^h + 0,071f_3^h + 0,576f_4^h - 1,062f_5^h + 0,054f_6^h$$

dengan:

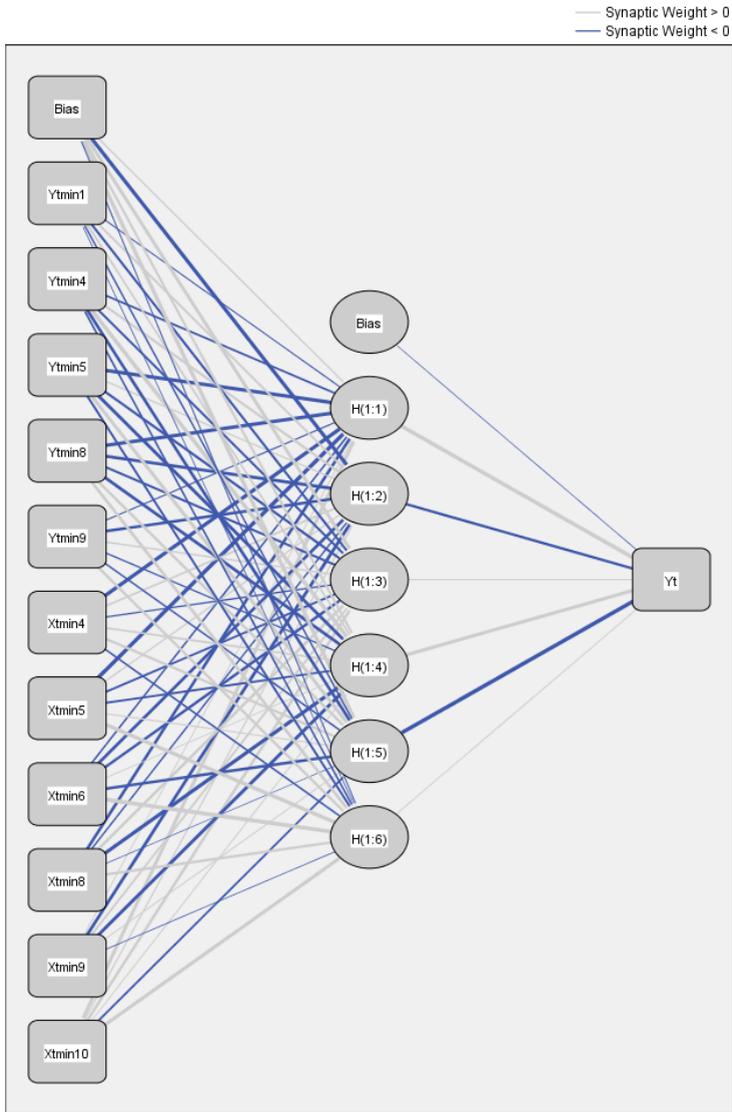
$\hat{Y}_{2,t}^*$  adalah nilai *standardized* dari  $\hat{Y}_{2,t}$

$f_j^h$  adalah fungsi aktivasi untuk *hidden layer* ke- $j$ ,  $j=1,2,\dots,6$

$$f_1^h = (1 + \exp(-(0,1 - 0,073Y_{2,t-1} - 0,173Y_{2,t-4} - 0,598Y_{2,t-5} - 0,594Y_{2,t-8} - 0,077Y_{2,t-9} - 0,631X_{1,t-4} - 0,801X_{1,t-5} - 0,133X_{1,t-6} - 0,374X_{1,t-8} + 0,042X_{1,t-9} + 0,543X_{1,t-10})))^{-1}$$

$$f_2^h = (1 + \exp(-(-0,615 + 0,202Y_{2,t-1} + 0,288Y_{2,t-4} + 0,085Y_{2,t-5} - 0,408Y_{2,t-8} - 0,366Y_{2,t-9} + 0,15X_{1,t-4} + 0,095X_{1,t-5} - 0,39X_{1,t-6} - 0,124X_{1,t-8} + 0,543X_{1,t-9} + 0,079X_{1,t-10})))^{-1}$$

$$f_3^h = (1 + \exp(-(0,494 - 0,278Y_{2,t-1} - 0,239Y_{2,t-4} - 0,303Y_{2,t-5} - 0,247Y_{2,t-8} + 0,119Y_{2,t-9} - 0,107X_{1,t-4} - 0,197X_{1,t-5} - 0,346X_{1,t-6} + 0,347X_{1,t-8} + 0,194X_{1,t-9} + 0,347X_{1,t-10})))^{-1}$$



Hidden layer activation function: Sigmoid

Output layer activation function: Identity

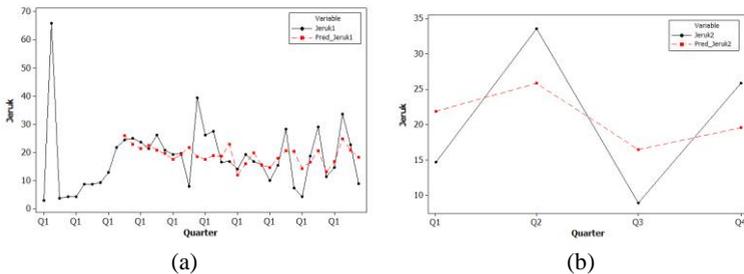
**Gambar 4.66** Arsitektur FFNN(11,6,1) Produktivitas Jeruk

$$f_4^h = (1 + \exp(-(0,262 + 0,155Y_{2,t-1} + 0,707Y_{2,t-4} - 0,475Y_{2,t-5} - 0,398Y_{2,t-8} - 0,096Y_{2,t-9} + 0,159X_{1,t-4} - 0,195X_{1,t-5} + 0,04X_{1,t-6} - 0,606X_{1,t-8} - 0,519X_{1,t-9} + 0,057X_{1,t-10})))^{-1}$$

$$f_5^h = (1 + \exp(-(0,661 - 0,131Y_{2,t-1} - 0,388Y_{2,t-4} + 0,537Y_{2,t-5} + 0,346Y_{2,t-8} - 0,131Y_{2,t-9} + 0,301X_{1,t-4} + 0,077X_{1,t-5} - 0,347X_{1,t-6} - 0,005X_{1,t-8} + 0,06X_{1,t-9} - 0,184X_{1,t-10})))^{-1}$$

$$f_6^h = (1 + \exp(-(-0,073 - 0,02Y_{2,t-1} - 0,148Y_{2,t-4} - 0,209Y_{2,t-5} + 0,382Y_{2,t-8} + 0,327Y_{2,t-9} - 0,135X_{1,t-4} + 0,644X_{1,t-5} + 0,802X_{1,t-6} + 0,304X_{1,t-8} - 0,011X_{1,t-9} + 0,589X_{1,t-10})))^{-1}$$

Secara visual, kebaikan model dapat juga dilihat melalui *plot time series* dari perbandingan data asli *training* dan *testing* dengan hasil ramalan dengan menggunakan metode FFNN. Berikut merupakan *Plot time series* perbandingan data asli dan data hasil ramalan pada produktivitas jeruk dijelaskan pada Gambar 4.67.



**Gambar 4.67** *Plot Time Series* Perbandingan (a) Data *Training* dan *Fits* (b) Data *Testing* dan Hasil Ramalan Model FFNN Produktivitas Jeruk

*Plot time series* pada Gambar 4.67 menunjukkan bahwa hasil *fits* untuk data *training* dan ramalan untuk data *testing* menunjukkan hasil yang baik ditunjukkan dengan ada beberapa garis yang berhimpit. Nilai ramalan pada data *testing* dan nilai *fits* pada data *training* juga sudah mengikuti pola data.

### C. Pemodelan Produktivitas Alpukat

Pemodelan produktivitas alpukat menggunakan deret *input*  $Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}, X_{t-4}, X_{t-5}, X_{t-8}, X_{t-9}$  dimana  $X$  adalah curah hujan. Berikut merupakan hasil nilai SSE data *testing* pada pemodelan produktivitas alpukat yang disajikan pada Tabel 4.31.

**Tabel 4.31** Nilai SSE Pemodelan FFNN pada Produktivitas Alpukat

Jumlah neuron	SSE data Testing				
	1	2	3	4	5
1	1,248	1,859	1,974	1,962	0,87
2	1,871	1,728	1,826	1,5	1,295
3	1,729	1,834	1,384	1,351	1,767
4	1,343	1,901	1,47	0,958	1,367
5	1,731	1,884	1,676	1,382	1,818
6	1,109	1,794	2	1,69	1,852
7	1,608	2,012	1,646	1,603	1,697
8	1,896	1,704	1,844	1,379	1,76
9	1,965	1,955	1,96	1,742	1,322
10	1,364	1,71	2	1,901	1,792

Model FFNN terbaik pada produktivitas alpukat adalah dengan neuron sebanyak 1 pada *hidden layer* dan pada replikasi ke-5 berdasarkan Tabel 4.31 dengan arsitektur FFNN(11,1,1) pada Gambar 4.68.

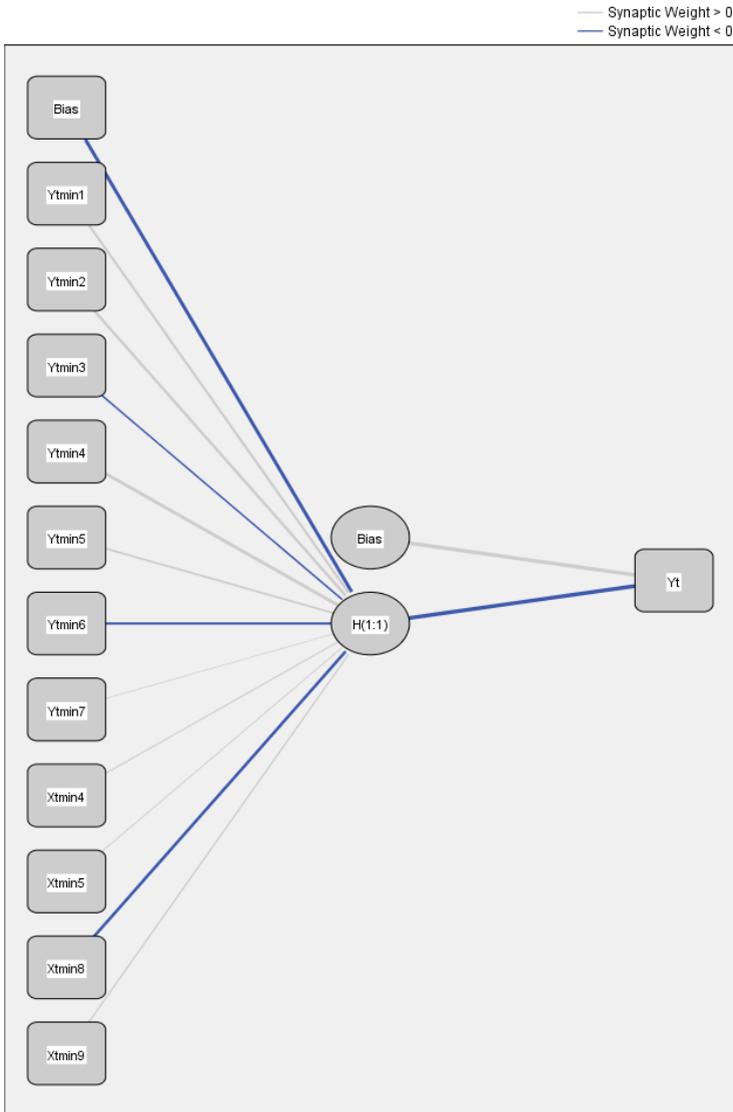
Arsitektur model FFNN(11,1,1) pada Gambar 4.68 secara matematis persamaan dapat dituliskan sebagai berikut:

$$\hat{Y}_{3,t}^* = 1,18 - 2,794f_1^h$$

dengan:

$\hat{Y}_{3,t}^*$  adalah nilai *standardized* dari  $\hat{Y}_{3,t}$

$f_j^h$  adalah fungsi aktivasi untuk *hidden layer* ke- $j$ ,  $j=1$



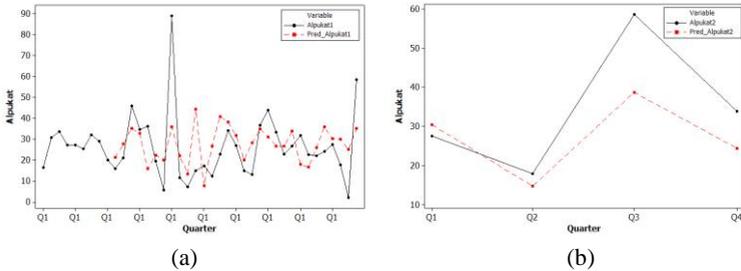
Hidden layer activation function: Sigmoid

Output layer activation function: Identity

**Gambar 4.68** Arsitektur FFNN(11,1,1) Produktivitas Alpukat

$$f_1^h = (1 + \exp(-(-0,512 + 0,226Y_{3,t-1} + 0,363Y_{3,t-2} - 0,143Y_{3,t-3} + 0,491Y_{3,t-4} + 0,144Y_{3,t-5} - 0,192Y_{3,t-6} + 0,016Y_{3,t-7} + 0,138X_{3,t-4} + 0,127X_{3,t-5} - 0,474X_{3,t-8} + 0,141X_{3,t-9})))^{-1}$$

Plot *time series* dapat juga digunakan untuk mengetahui kebaikan model dari perbandingan data asli *training* dan *testing* dengan hasil ramalan dengan menggunakan metode FFNN. Berikut merupakan *Plot time series* perbandingan data asli dan data hasil ramalan pada produktivitas alpukat dijelaskan pada Gambar 4.69.



**Gambar 4.69** *Plot Time Series* Perbandingan (a) Data *Training* dan *Fits* (b) Data *Testing* dan Hasil Ramalan Model FFNN Produktivitas Alpukat

Hasil plot *time series* pada Gambar 4.69 menunjukkan bahwa hasil *fits* untuk data *training* dan ramalan untuk data *testing* menunjukkan hasil yang baik ditunjukkan dengan ada beberapa garis yang berhimpit. Hasil ramalan pada data *testing* maupun *training* juga sudah mengikuti pola data.

**D. Pemodelan Produktivitas Jambu Biji**

Pemodelan produktivitas jambu biji menggunakan deret *input*  $Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}, Y_{t-8}, Y_{t-9}, Y_{t-10}, Y_{t-11}, X_{t-3}, X_{t-4}, X_{t-7}, X_{t-8}$  dimana  $X$  adalah curah hujan. Berikut merupakan hasil nilai SSE data *testing* pada pemodelan produktivitas jambu biji yang disajikan pada Tabel 4.32.

Nilai SSE data *testing* pada Tabel 4.32 menunjukkan bahwa model FFNN terbaik pada produktivitas jambu biji adalah

dengan neuron sebanyak 4 pada *hidden layer* dan pada replikasi ke-4 dengan arsitektur FFNN(15,4,1) pada Gambar 4.70.

**Tabel 4.32** Nilai SSE Pemodelan FFNN pada Produktivitas Jambu biji

Jumlah neuron	SSE data <i>Testing</i>				
	1	2	3	4	5
1	0,823	0,811	0,581	0,789	0,821
2	0,664	0,723	0,484	0,728	0,691
3	0,711	0,708	0,709	0,725	0,837
4	0,818	0,664	0,717	0,341	0,752
5	0,809	0,805	0,657	0,842	0,699
6	0,616	0,659	0,88	0,809	0,919
7	0,634	0,761	0,855	0,766	1,007
8	0,591	0,68	0,653	0,927	0,762
9	0,849	0,382	0,598	0,816	0,605
10	0,944	0,825	1,001	0,356	0,474

Secara matematis persamaan untuk model FFNN(15,4,1) dapat dituliskan sebagai berikut:

$$\hat{Y}_{4,t}^* = -0,391 - 0,281f_1^h + 0,084f_2^h + 0,45f_3^h + 0,669f_4^h$$

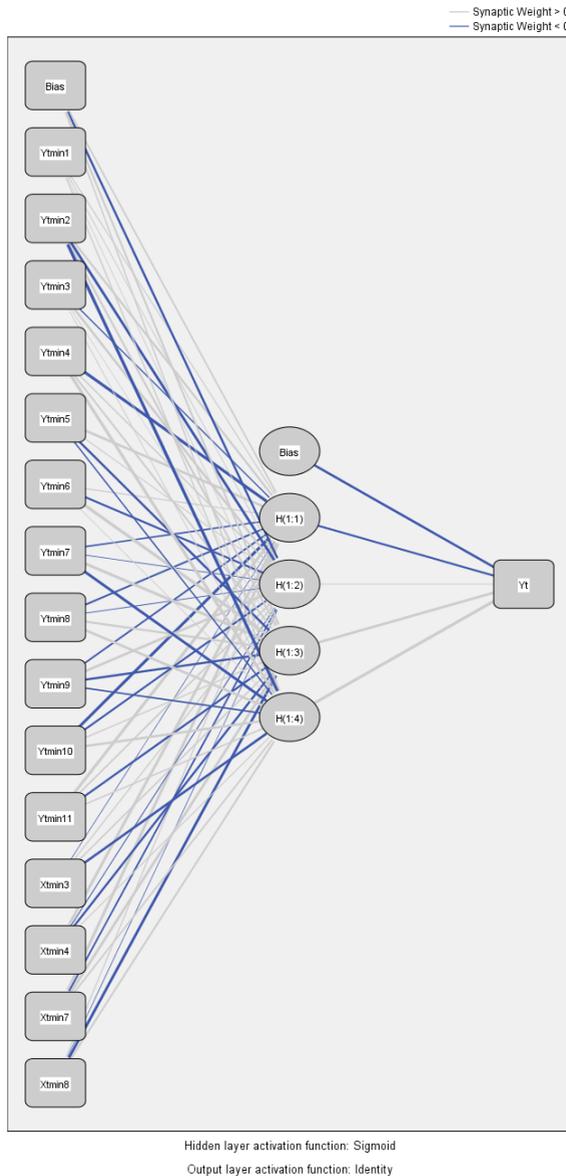
dengan:

$\hat{Y}_{4,t}^*$  adalah nilai *standardized* dari  $\hat{Y}_{4,t}$

$f_j^h$  adalah fungsi aktivasi untuk *hidden layer* ke- $j$ ,  $j=1,2,3,4$

$$f_1^h = (1 + \exp(-(0,208 + 0,11Y_{4,t-1} + 0,305Y_{4,t-2} - 0,15Y_{4,t-3} - 0,634Y_{4,t-4} + 0,425Y_{4,t-5} + 0,143Y_{4,t-6} - 0,196Y_{4,t-7} - 0,242Y_{4,t-8} - 0,218Y_{4,t-9} - 0,612Y_{4,t-10} + 0,614Y_{4,t-11} - 0,041X_{3,t-3} + 0,543X_{3,t-4} + 0,58X_{3,t-7} + 0,112X_{3,t-8})))^{-1}$$

$$f_2^h = (1 + \exp(-(-0,373 + 0,082Y_{4,t-1} - 0,464Y_{4,t-2} + 0,383Y_{4,t-3} + 0,188Y_{4,t-4} + 0,102Y_{4,t-5} - 0,299Y_{4,t-6} - 0,06Y_{4,t-7} - 0,068Y_{4,t-8} + 0,433Y_{4,t-9} - 0,258Y_{4,t-10} + 0,213Y_{4,t-11} + 0,145X_{3,t-3} - 0,083X_{3,t-4} - 0,218X_{3,t-7} - 0,044X_{3,t-8})))^{-1}$$

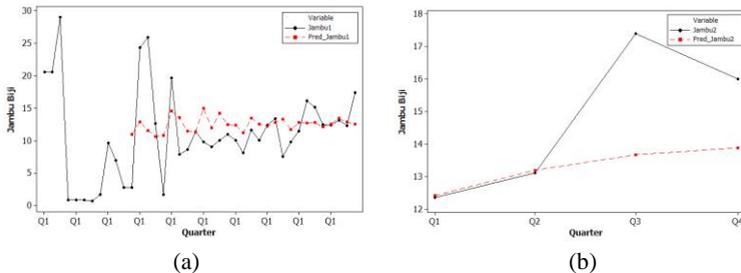


**Gambar 4.70** Arsitektur FFNN(15,4,1) Produktivitas Jambi Biji

$$f_3^h = (1 + \exp(-(0.247 + 0,05 Y_{4,t-1} + 0,25 Y_{4,t-2} + 0,02 Y_{4,t-3} + 0,222 Y_{4,t-4} - 0,376 Y_{4,t-5} + 0,678 Y_{4,t-6} + 0,60 Y_{4,t-7} + 0,366 Y_{4,t-8} - 0,372 Y_{4,t-9} + 0,155 Y_{4,t-10} - 0,365 Y_{4,t-11} + 0,189 X_{3,t-3} - 0,367 X_{3,t-4} + 0,451 X_{3,t-7} - 0,48 X_{3,t-8})))^{-1}$$

$$f_4^h = (1 + \exp(-(0.168 + 0,158 Y_{4,t-1} - 0,67 Y_{4,t-2} + 0,076 Y_{4,t-3} + 0,67 Y_{4,t-4} - 0,169 Y_{4,t-5} + 0,049 Y_{4,t-6} - 0,507 Y_{4,t-7} + 0,445 Y_{4,t-8} - 0,197 Y_{4,t-9} + 0,38 Y_{4,t-10} + 0,189 Y_{4,t-11} - 0,392 X_{3,t-3} + 0,103 X_{3,t-4} + 0,204 X_{3,t-7} + 0,243 X_{3,t-8})))^{-1}$$

Kebaikan model dapat juga dilihat melalui *plot time series* dari perbandingan data asli *training* dan *testing* dengan hasil ramalan dengan menggunakan metode FFNN. Berikut merupakan *Plot time series* perbandingan data asli dan data hasil ramalan pada produktivitas jambu biji dijelaskan pada Gambar 4.71.



**Gambar 4.71** Plot Time Series Perbandingan (a) Data *Training* dan *Fits* (b) Data *Testing* dan Hasil Ramalan Model FFNN Produktivitas Jambu Biji

Kebaikan model yang ditunjukkan pada Gambar 4.71 diperoleh hasil bahwa nilai *fits* untuk data *training* dan ramalan untuk data *testing* menunjukkan hasil yang kurang baik ditunjukkan dengan tidak berhimpitnya kedua garis.

## E. Pemodelan Produktivitas Pisang

Pemodelan produktivitas pisang menggunakan deret *input* sesuai dengan hasil pemodelan pada ARIMA yaitu model ARIMA ([9],1,0) dengan deret *input*  $Y_{t-1}$ ,  $Y_{t-9}$ , dan  $Y_{t-10}$ . Berikut

merupakan hasil nilai SSE data *testing* pada pemodelan produktivitas pisang yang disajikan pada Tabel 4.33.

**Tabel 4.33** Nilai SSE Pemodelan FFNN pada Produktivitas Pisang

Jumlah neuron	SSE data <i>Testing</i>				
	1	2	3	4	5
1	0,507	0,548	0,42	0,474	0,462
2	0,528	0,492	0,522	0,458	0,604
3	0,518	0,507	0,601	0,542	0,455
4	0,414	0,468	0,427	0,444	0,467
5	0,641	0,312	0,537	0,5	0,37
6	0,634	0,443	0,617	0,557	0,58
7	0,571	0,501	0,564	0,414	0,449
8	0,418	0,449	0,456	0,615	0,589
9	0,582	0,398	0,524	0,483	0,445
10	0,684	0,522	0,756	0,592	0,442

Hasil yang ditunjukkan pada Tabel 4.33 diperoleh bahwa model FFNN terbaik pada produktivitas pisang adalah dengan neuron sebanyak 5 pada *hidden layer* dan pada replikasi ke-2 dengan arsitektur FFNN(3,5,1) pada Gambar 4.72.

Secara matematis persamaan untuk model FFNN(3,5,1) dapat dituliskan sebagai berikut:

$$\hat{Y}_{5,t}^* = 0,751 - 0,555f_1^h - 2,042f_2^h - 2,092f_3^h + 2,757f_4^h + 0,118f_5^h$$

dengan:

$\hat{Y}_{5,t}^*$  adalah nilai *standardized* dari  $\hat{Y}_{5,t}$

$f_j^h$  adalah fungsi aktivasi untuk *hidden layer* ke- $j$ ,  $j=1,2,\dots,5$

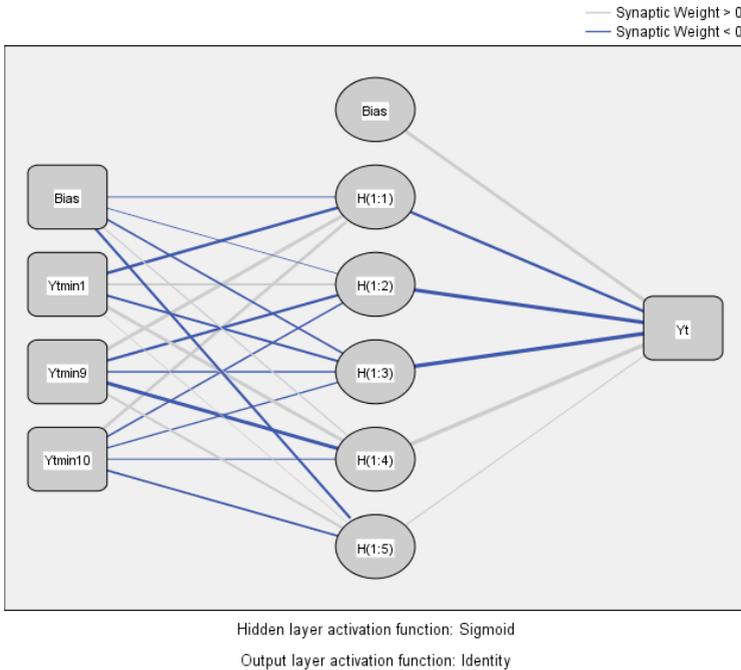
$$f_1^h = (1 + \exp(-(-0,025 - 0,625Y_{5,t-1} + 1,256Y_{5,t-9} + 0,738Y_{5,t-10})))^{-1}$$

$$f_2^h = (1 + \exp(-(-0,01 + 0,271Y_{5,t-1} - 0,446Y_{5,t-9} - 0,217Y_{5,t-10})))^{-1}$$

$$f_3^h = (1 + \exp(-(-0,242 - 0,311Y_{5,t-1} - 0,214Y_{5,t-9} - 0,179Y_{5,t-10})))^{-1}$$

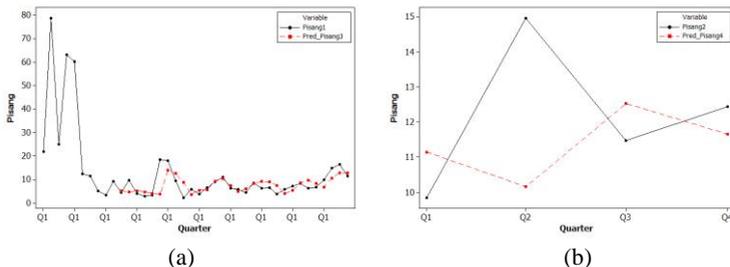
$$f_4^h = (1 + \exp(-(-0,118 + 1,225Y_{5,t-1} - 1,442Y_{5,t-9} - 0,052Y_{5,t-10})))^{-1}$$

$$f_5^h = (1 + \exp(-(-0,446 + 0,003Y_{5,t-1} + 0,423Y_{5,t-9} - 0,269Y_{5,t-10})))^{-1}$$



**Gambar 4.72** Arsitektur FFNN(3,5,1) Produktivitas Pisang

Kebaikan model dapat juga dilihat melalui *plot time series* dari perbandingan data asli *training* dan *testing* dengan hasil ramalan dengan menggunakan metode FFNN. Berikut merupakan *Plot time series* perbandingan data asli dan data hasil ramalan pada produktivitas pisang dijelaskan pada Gambar 4.73.



**Gambar 4.73** Plot Time Series Perbandingan (a) Data Training dan Fits (b) Data Testing dan Hasil Ramalan Model FFNN Produktivitas Pisang

Plot *time series* pada Gambar 4.73 menunjukkan hasil *fits* untuk data *training* dan ramalan untuk data *testing* menunjukkan hasil yang baik ditunjukkan dengan berhimpitnya kedua garis. Namun pada hasil nilai ramalan untuk data *testing* menunjukkan hasil yang kurang baik, karena tidak ada titik yang berhimpit antar kedua garis.

### 4.3 Pemilihan Model Terbaik dan Peramalan Produktivitas Buah di Kota Batu

Sebelum melakukan peramalan terhadap produktivitas lima buah di Kota Batu periode mendatang, maka dilakukan terlebih dahulu pemilihan model terbaik berdasarkan metode ARIMA, Fungsi Transfer, dan FFNN. Berikut merupakan perhitungan RMSEP dan MAPEP pada masing-masing metode pada Tabel 4.34.

**Tabel 4.34** Pemilihan Model Terbaik

Produktivitas	ARIMA		Fungsi Transfer		FFNN	
	RMSEP	MAPEP	RMSEP	MAPEP	RMSEP	MAPEP
Apel	1,04	9,92	2,19	28,00	<b>0,18</b>	<b>2,13</b>
Jeruk	7,67	28,44	39,88	269,25	<b>7,22</b>	<b>45,27</b>
Alpukat	24,79	886,15	11,93	31,94	<b>11,21</b>	<b>22,52</b>
Jambu Biji	1,32	9,39	2,58	15,16	<b>2,14</b>	<b>8,94</b>
Pisang	3,84	24,88	-	-	<b>2,28</b>	<b>19,72</b>

Nilai RMSEP dan MAPEP yang ditunjukkan pada Tabel 4.34 diperoleh hasil bahwa model terbaik untuk produktivitas apel, jeruk, alpukat, jambu biji, dan pisang adalah model FFNN. Selanjutnya dilakukan peramalan untuk triwulan I sampai triwulan IV tahun 2019. Dimana peramalan dengan model FFNN ini menggunakan nilai variabel prediktor yang harus diketahui terlebih dahulu, sehingga dilakukan peramalan nilai variabel prediktor terlebih dahulu dengan model ARIMA yang telah diperoleh pada pemodelan sebelumnya. Berikut merupakan hasil peramalan produktivitas buah di Kota Batu.

**Tabel 4.35** Peramalan Produktivitas Buah pada Tahun 2019

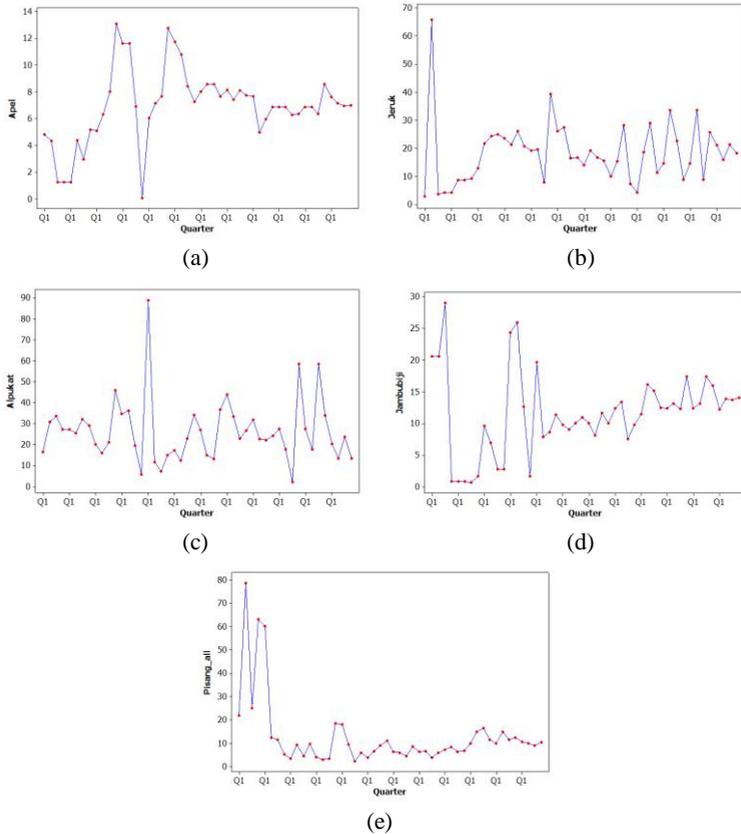
Periode	Apel	Jeruk	Alpukat	Jambu biji	Pisang
Triwulan I	7,63	21,27	20,46	12,19	10,54
Triwulan II	7,15	15,92	13,35	13,93	9,79
Triwulan III	6,96	21,34	23,72	13,73	8,95
Triwulan IV	7	18,23	13,43	14,09	10,38

Hasil peramalan ditunjukkan pada Tabel 4.35 dapat dilihat bahwa prediksi produktivitas buah paling tinggi adalah jeruk dan alpukat, dimana produktivitas jeruk paling tinggi pada triwulan I dan III yaitu 22 kg/pohon. Sedangkan produktivitas alpukat paling tinggi sama yaitu pada triwulan I dan III yang mencapai 21kg/pohon dan 24 kg/pohon.

Produktivitas buah paling sedikit masih sama dengan periode sebelumnya yaitu apel, dimana tahun 2019 diprediksi memiliki produktivitas 7-8 kg/pohon. Prediksi produktivitas jambu biji dan pisang di tahun 2019 hampir sama yaitu berkisar antara 12-14 kg/pohon. Selanjutnya dilakukan analisis *time series plot* antara data dengan data hasil prediksi yang ditunjukkan pada Gambar 4.74.

Plot *time series* pada Gambar 4.74 dapat disimpulkan bahwa produktivitas apel (a) tahun 2019 diprediksi mengalami penurunan dibandingkan tahun 2018 sebesar 0,07%. Produktivitas jeruk (b) dibandingkan tahun 2018, tahun 2019 diprediksi mengalami peningkatan sebesar 8,23% dan cenderung stabil. Produktivitas alpukat (c) pada tahun 2019 diprediksi mengalami peningkatan yang jauh lebih tinggi dibandingkan pada tahun 2018 yaitu sebesar 94,37%. Pada tahun 2019, pada triwulan III produktivitas alpukat diprediksi paling tinggi, sedangkan pada triwulan II dan IV diprediksi produktivitas alpukat paling rendah. Produktivitas jambu biji (d) pada tahun 2019 diprediksi terjadi penurunan dibandingkan tahun 2018 sebesar 9,14%. Produktivitas pisang (e) pada tahun 2019 diprediksi mengalami peningkatan secara keseluruhan dibandingkan tahun 2018 sebesar 22,82%. Namun, pada tahun 2019 produktivitas pisang stabil atau tidak

berfluktuasi tinggi antar triwulan. Secara umum produktivitas jeruk, alpukat, dan pisang di Kota Batu diprediksi mengalami peningkatan di tahun 2019, sedangkan produktivitas apel dan jambu biji mengalami penurunan.



**Gambar 4.74** *Plot Time Series* Produktivitas Buah dan Hasil Ramalan  
 (a) Apel (b) Jeruk (c) Alpukat (d) Jambu Biji (e) Pisang

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan hasil analisis peramalan produktivitas lima buah yang ada di Kota Batu dengan metode ARIMA, Fungsi Transfer, dan FFNN dapat disimpulkan bahwa :

1. Produktivitas alpukat, jambu biji, dan pisang tidak berpola musiman. Sedangkan produktivitas apel dan jeruk diindikasikan memiliki pola musiman. Suhu, kelembaban, dan curah hujan juga memiliki pola yang musiman.
2. Model terbaik untuk produktivitas buah di Kota Batu adalah dengan metode FFNN. Hasil analisis menunjukkan bahwa produktivitas apel, jambu biji, dan alpukat dipengaruhi oleh curah hujan, sedangkan produktivitas jeruk dipengaruhi oleh suhu. Pola data hubungan antara produktivitas buah dengan deret *input* adalah linier.
3. Hasil peramalan produktivitas jeruk, alpukat, dan pisang di Kota Batu diprediksi mengalami peningkatan di tahun 2019 masing-masing sebesar 8,23%, 94,38%, dan 22,82%, sedangkan produktivitas apel dan jambu biji mengalami penurunan masing-masing sebesar 0,07% dan 9,14%.

#### **5.2 Saran**

Berdasarkan hasil analisis peramalan produktivitas lima buah yang ada di Kota Batu di atas dapat diberikan saran untuk penelitian selanjutnya agar lebih teliti dalam pengambilan data serta dalam penentuan model dugaan agar model yang terbaik yang didapat dapat meramalkan dengan tepat produktivitas buah yang ada di Kota Batu. Sedangkan untuk Dinas Pertanian dan Kehutanan Kota Batu dapat dijadikan informasi bahwa diprediksi akan terjadi penurunan produktivitas apel dan jambu biji di Kota Batu pada tahun 2019. Agar dilakukan tindakan untuk mencegah terjadinya hal tersebut.

*Halaman ini sengaja dikosongkan*

## DAFTAR PUSTAKA

- Aditiyas, W., Haji, A., & Rahadi, J. (2005). Analisis Spasial untuk Evaluasi Kesesuaian Lahan Tanaman Apel di Kota Batu-Jawa Timur. *Jurnal Sumberdaya Alam dan Lingkungan Vol.1 No.2*, 1-7.
- Ahmad, D. (2018). *Pengertian Suhu Udara*. Dipetik 21-10-2018, dari Sridianti.com.
- Badan Pusat Statistik Kota Batu. (2017). *Statistik Daerah Kota Batu 2017*. Kota Batu: Badan Pusat Statistik Kota Batu.
- Beale, & Hudson, M. (2010). *Neural Network Toolbox TM 7 User's Guide*. Natick: The Math Works, Inc.
- Chen, Z., & Yang, Y. (2004). Assessing Forecast Accuracy Measures. *Working Paper*, hal.10.
- Farber, R., & Lapedes, A. (2008). How Neural Nets Works. *Evolution, Learning, and Cognition Vol.1 No.2*, 331-345.
- Faulina, R. (2014). Perbandingan Akurasi Ensemble ARIMA dalam Peramalan Curah Hujan di Kota Batu, Malang, Jawa Timur. *Jurnal Matematika, Sains, dan Teknologi Vol.15 No.2*, 75-83.
- Handaga, B., & Asy'ari, H. (2012). Kombinasi Algoritma Cuckoo-Search dan Levenbergmarquadt (CS-LM) pada Proses Pelatihan Artificial Neural Network (ANN). *Symposium Nasional RAPI XI FT UMS*.
- Ibrahim, J. T., Baroh, I., & Sasmito, B. D. (2016). Keputusan Petani Tetap Menanam Apel. *Seminar Nasional Pembangunan Pertanian* (hal. 425-428). Malang: Unmuh Malang.
- IPCC. (2007). *Climate Change 2007-Impacts, Adaptation and Vulnerability*. New York: Cambridge University.
- Lee, T., White, H., & Granger, C. (1993). Testing for Neglected Nonlinearity in Time Series Models. *Journal of Econometrics* 56, 269-290.

- Ruminta, & Handoko. (2011). *Kajian risiko dan adaptasi perubahan iklim pada sektor pertanian di Malang Raya*. KLH Jakarta: Laporan Penelitian.
- Setiawan, W. (2008). Prediksi Harga Saham Menggunakan Jaringan Saraf Tiruan Multilayer FFNN dengan Algoritma Backpropagation. *Makalah disajikan dalam Konferensi Nasional Sistem dan Informasi*, 108-113. Bali.
- Sitompul, S. M. (2007). *Kendala Produktivitas Tanaman Apel (Malus sylvestris Mill) di Wilayah Malang Raya*. Malang: Seminar Hasil Penelitian PHK A2, Jurusan Budidaya Pertanian, Faperta Universitas Brawijaya.
- Soelarso, R. B. (1996). *Budidaya Apel*. Yogyakarta: Kanisius.
- Suhartono. (2007). *Feedforward Neural Network untuk Pemodelan Runtun Waktu*. Yogyakarta: Disertasi Doktorat, Universitas Gajah Mada.
- Syabbuddin, H., Manabu, D. Y., & Eleonora, R. (2004). *Impact of climate change to dry land water budget in Indonesia : observation 1980-2002 and simultan for 2010-2039*. Kobe University: Graduate School of Science and Technology.
- Syarifah, U. (2018). Metode ARIMAX, FFNN, dan Hybrid ARIMAX-FFNN untuk Peramalan Pertamax. *Tugas Akhir*. Institut Teknologi Sepuluh Nopember (ITS). Surabaya.
- Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods*. Canada: Addison Wesley Publishing Company.

## LAMPIRAN

**Lampiran 1.** Data Suhu Rata-rata, Suhu Maksimum, Curah Hujan, dan Kelembaban di Kota Batu.

Tahun	Triwulan	Suhu Maksimum	Suhu Rata-rata	Kelembaban	Curah Hujan
2008	I	26.90	21.50	83.00	1026
2008	II	26.77	21.07	76.33	178
2008	III	26.07	20.57	72.67	28
2008	IV	26.90	22.43	79.33	605
2009	I	25.77	21.67	79.67	937
2009	II	26.67	22.13	76.33	195
2009	III	26.67	21.07	70.33	15
2009	IV	27.70	22.73	73.67	417
2010	I	26.90	23.03	82.33	1002.5
2010	II	29.93	23.13	83.67	635
2010	III	26.70	22.77	79.33	330.5
2010	IV	26.83	23.20	78.33	765
2011	I	26.33	22.33	78.00	368
2011	II	25.83	21.53	79.00	453.5
2011	III	25.80	20.73	71.67	10
2011	IV	27.07	22.20	78.00	635
2012	I	27.93	23.60	80.33	919.9
2012	II	28.23	23.40	74.00	106.5
2012	III	27.30	22.03	68.33	4
2012	IV	29.47	24.37	78.00	738
2013	I	28.70	23.97	83.33	877.4
2013	II	28.60	23.93	82.00	525.8
2013	III	26.70	22.33	74.67	89
2013	IV	28.97	23.87	79.00	834.5

**Lampiran 1.** Data Suhu Rata-rata, Suhu Maksimum, Curah Hujan, dan Kelembaban di Kota Batu (Lanjutan)

Tahun	Triwulan	Suhu Maksimum	Suhu Rata-rata	Kelembaban	Curah Hujan
2014	I	28.37	23.70	80.67	523
2014	II	29.17	23.90	78.67	187
2014	III	28.37	22.33	74.33	24
2014	IV	29.93	24.37	76.33	523
2015	I	32.27	25.73	73.67	790
2015	II	31.57	25.27	73.33	683
2015	III	32.27	24.53	74.67	0
2015	IV	33.90	27.07	77.67	422
2016	I	27.33	22.67	93.67	840
2016	II	27.67	23.00	92.33	366
2016	III	27.00	22.00	88.67	194
2016	IV	27.67	23.00	85.67	869
2017	I	27.00	22.33	92.33	918
2017	II	27.00	22.00	91.67	363
2017	III	26.67	21.33	91.33	13
2017	IV	27.33	22.67	92.00	629
2018	I	26.93	22.27	94.00	739
2018	II	28.07	22.23	94.33	126
2018	III	26.53	20.37	95.00	24
2018	IV	28.30	22.60	91.00	362

**Lampiran 2.** Data Produktivitas Apel, Jeruk, Alpukat, Jambu biji, dan Pisang

Tahun	Triwulan	Apel	Jeruk	Alpukat	Jambu Biji	Pisang
2008	I	4.81	2.95	16.48	20.61	21.85
2008	II	4.33	65.95	30.95	20.61	78.66
2008	III	1.25	3.76	33.74	29.00	25.12
2008	IV	1.28	4.39	27.31	0.87	63.18
2009	I	1.27	4.37	27.31	0.87	60.19
2009	II	4.38	8.71	25.48	0.89	12.45
2009	III	2.97	8.77	32.15	0.72	11.56
2009	IV	5.20	9.26	29.16	1.74	5.13
2010	I	5.12	12.94	19.98	9.61	3.27
2010	II	6.35	21.85	15.90	6.92	9.31
2010	III	8.05	24.47	21.17	2.78	4.41
2010	IV	13.12	24.99	46.04	2.79	9.74
2011	I	11.66	23.74	34.76	24.34	4.03
2011	II	11.63	21.38	36.16	25.94	2.97
2011	III	6.94	26.16	19.62	12.65	3.37
2011	IV	0.06	20.74	5.80	1.65	18.47
2012	I	6.07	19.23	88.91	19.70	18.00
2012	II	7.17	19.69	11.67	7.89	9.50
2012	III	7.70	7.87	7.23	8.62	2.30
2012	IV	12.81	39.46	15.05	11.39	5.79
2013	I	11.78	26.17	17.28	9.81	3.70
2013	II	10.80	27.50	12.39	9.03	6.48
2013	III	8.42	16.63	22.87	10.08	9.06
2013	IV	7.29	16.72	34.25	10.98	10.97

**Lampiran 2.** Data Produktivitas Apel, Jeruk, Alpukat, Jambu biji, dan Pisang (Lanjutan)

Tahun	Triwulan	Apel	Jeruk	Alpukat	Jambu Biji	Pisang
2014	I	8.02	14.07	27.03	10.07	6.18
2014	II	8.59	19.35	15.03	8.13	5.91
2014	III	8.60	16.75	13.25	11.65	4.51
2014	IV	7.67	15.61	36.83	10.05	8.45
2015	I	8.15	10.08	43.92	12.42	6.39
2015	II	7.46	15.41	33.34	13.39	6.46
2015	III	8.13	28.27	22.98	7.50	3.70
2015	IV	7.76	7.38	26.87	9.80	5.89
2016	I	7.68	4.22	31.89	11.45	7.08
2016	II	4.98	18.73	22.57	16.16	8.35
2016	III	5.99	29.03	22.08	15.12	6.18
2016	IV	6.91	11.38	24.26	12.46	6.78
2017	I	6.89	14.71	27.53	12.36	9.85
2017	II	6.88	33.59	17.92	13.11	14.96
2017	III	6.30	22.69	2.25	12.32	16.55
2017	IV	6.36	8.90	58.60	17.40	11.47
2018	I	6.89	14.71	27.53	12.36	9.85
2018	II	6.88	33.59	17.92	13.11	14.96
2018	III	6.36	8.90	58.60	17.40	11.47
2018	IV	8.59	25.87	33.88	16.00	12.43

### Lampiran 3. Output Model ARIMA Produktivitas Apel

#### a. Model ARIMA 1

**Conditional Least Squares Estimation**

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
AR1,1	-0.40549	0.14843	-2.73	0.0095	4

Variance Estimate      4.686359  
Std Error Estimate      2.1648  
AIC                              171.9057

**Autocorrelation Check of Residuals**

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	2.86	5	0.7219	-0.126	-0.045	-0.140	-0.011	-0.142	0.076	
12	6.75	11	0.8193	-0.013	0.053	-0.007	-0.152	0.030	0.202	
18	9.16	17	0.9350	0.004	-0.070	-0.014	-0.003	-0.161	0.050	
24	12.79	23	0.9554	0.098	-0.049	-0.012	-0.138	0.087	-0.030	

**Tests for Normality**

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W      0.96002	Pr < W      0.1786
Kolmogorov-Smirnov	D      0.114426	Pr > D      >0.1500
Cramer-von Mises	W-Sq   0.097067	Pr > W-Sq   0.1219
Anderson-Darling	A-Sq   0.592966	Pr > A-Sq   0.1184

#### b. Model ARIMA 2

**Conditional Least Squares Estimation**

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1,1	0.33104	0.15475	2.14	0.0389	4

Variance Estimate      4.842732  
Std Error Estimate      2.200621  
AIC                              173.1858

**Autocorrelation Check of Residuals**

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	2.94	5	0.7099	-0.108	-0.053	-0.141	-0.074	-0.143	0.070	
12	7.26	11	0.7775	-0.020	0.170	-0.029	-0.146	0.027	0.163	
18	9.27	17	0.9316	-0.003	-0.070	-0.015	0.009	-0.148	0.032	
24	12.30	23	0.9656	0.093	-0.031	0.000	-0.133	0.072	-0.023	

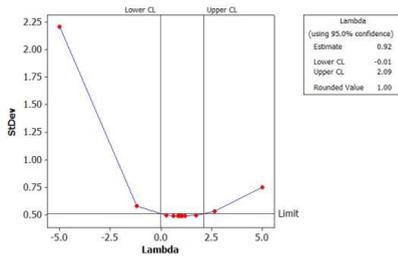
**Tests for Normality**

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W      0.948462	Pr < W      0.0729
Kolmogorov-Smirnov	D      0.139774	Pr > D      0.0529
Cramer-von Mises	W-Sq   0.156899	Pr > W-Sq   0.0195
Anderson-Darling	A-Sq   0.863388	Pr > A-Sq   0.0242

**Forecasts for variable y**

Obs	Forecast	Std Error	95% Confidence Limits	
41	6.3451	2.2006	2.0320	10.6583
42	6.6640	3.1121	0.5543	12.7637
43	6.7338	3.8116	-0.7367	14.2044
44	6.6369	4.4012	-1.9893	15.2632

## Lampiran 4. Output Model ARIMA Produktivitas Jeruk



### a. Model ARIMA 1

#### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MU	2.66699	0.14276	18.68	<.0001	0
AR1,1	0.29011	0.16077	1.80	0.0791	4

Constant Estimate 1.893282  
 Variance Estimate 0.451421  
 Std Error Estimate 0.671879  
 AIC 83.64918  
 SBC 87.02694  
 Number of Residuals 40

\* AIC and SBC do not include log determinant.

#### Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.71	5	0.5912	0.064	0.139	0.188	0.022	-0.013	-0.145
12	5.87	11	0.8817	-0.053	-0.030	-0.103	-0.047	-0.031	-0.143
18	9.43	17	0.9257	0.010	-0.010	-0.012	-0.035	-0.209	0.060
24	11.90	23	0.9719	-0.131	-0.059	-0.011	-0.056	0.001	0.069

#### Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.951333	Pr < W 0.0843
Kolmogorov-Smirnov	D 0.124001	Pr > D 0.1220
Cramer-von Mises	W-Sq 0.152552	Pr > W-Sq 0.0218
Anderson-Darling	A-Sq 0.864033	Pr > A-Sq 0.0242

#### Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
41	2.6733	0.6719	1.3564	3.9902
42	2.9128	0.6719	1.5959	4.2296
43	2.7990	0.6719	1.4822	4.1159
44	2.5275	0.6719	1.2106	3.8444

### b. Model ARIMA 2

#### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MU	2.68414	0.13248	20.26	<.0001	0
MA1,1	-0.27901	0.16160	-1.73	0.0924	4

Constant Estimate 2.68414  
 Variance Estimate 0.451366  
 Std Error Estimate 0.671839  
 AIC 83.64442  
 SBC 87.02218  
 Number of Residuals 40

\* AIC and SBC do not include log determinant.

## Lampiran 4. Output Model ARIMA Produktivitas Jeruk (Lanjutan)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.34	5	0.6475	0.048	0.127	0.189	0.020	-0.003	-0.135
12	5.86	11	0.8827	-0.053	0.029	-0.124	-0.029	-0.031	-0.152
18	9.71	17	0.9154	0.011	-0.023	-0.025	-0.034	-0.215	0.064
24	12.38	23	0.9642	-0.131	-0.063	0.004	-0.069	-0.012	0.069

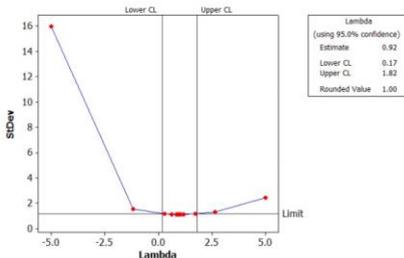
### Tests for Normality

Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.950919	Pr < W	0.0816
Kolmogorov-Smirnov	D	0.137045	Pr > D	0.0574
Cramer-von Mises	W-Sq	0.158034	Pr > W-Sq	0.0190
Anderson-Darling	A-Sq	0.883207	Pr > A-Sq	0.0224

### Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
41	2.7753	0.6718	1.4585	4.0920
42	2.8970	0.6718	1.5802	4.2138
43	2.7671	0.6718	1.4503	4.0839
44	2.5493	0.6718	1.2326	3.8661

## Lampiran 5. Output Model ARIMA Produktivitas Alpukat



### a. Model ARIMA 1

#### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MU	4.95953	0.15797	31.40	<.0001	0
MA1,1	0.28834	0.17600	1.64	0.1096	2

Constant Estimate      4.959526  
 Variance Estimate      1.897727  
 Std Error Estimate      1.37758  
 AIC                      141.0896  
 SBC                      144.4674  
 Number of Residuals    40  
 \* AIC and SBC do not include log determinant.

## Lampiran 5. Output Model ARIMA Produktivitas Alpakat (Lanjutan)

**Autocorrelation Check of Residuals**

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	1.65	5	0.8955	-0.132	0.002	0.030	0.035	0.057	-0.114	
12	4.77	11	0.9419	-0.061	-0.097	-0.128	-0.127	0.012	0.103	
18	7.41	17	0.3777	-0.085	-0.141	-0.001	0.049	0.100	-0.011	
24	20.37	23	0.6197	0.020	0.014	0.051	-0.252	0.250	-0.072	

**Tests for Normality**

Test	--Statistic--	----p Value-----
Shapiro-Wilk	W 0.95866	Pr < W 0.1507
Kolmogorov-Smirnov	D 0.119373	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.079011	Pr > W-Sq 0.2147
Anderson-Darling	A-Sq 0.520882	Pr > A-Sq 0.1825

**Forecasts for variable y**

Obs	Forecast	Std Error	95% Confidence Limits	
41	5.9339	1.3776	3.2339	8.6339
42	4.2438	1.3776	1.5438	6.9438
43	4.9595	1.4337	2.1495	7.7695
44	4.9595	1.4337	2.1495	7.7695

### b. Model ARIMA 2

**Conditional Least Squares Estimation**

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MU	5.01016	0.17461	28.69	<.0001	0
ARI,1	-0.45309	0.21898	-2.07	0.0454	22

Constant Estimate 7.280205  
 Variance Estimate 1.811565  
 Std Error Estimate 1.345944  
 AIC 139.231  
 SBC 142.6088  
 Number of Residuals 40  
 \* AIC and SBC do not include log determinant.

**Autocorrelation Check of Residuals**

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	4.31	5	0.5054	-0.030	-0.277	-0.013	0.065	0.097	-0.066	
12	10.06	11	0.5251	-0.029	-0.097	-0.179	-0.114	0.111	0.184	
18	15.25	17	0.5776	-0.109	-0.213	-0.011	0.086	0.116	-0.014	
24	20.66	23	0.6017	0.008	0.019	-0.090	-0.000	0.180	-0.118	

**Tests for Normality**

Test	--Statistic--	----p Value-----
Shapiro-Wilk	W 0.959063	Pr < W 0.1556
Kolmogorov-Smirnov	D 0.101133	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.03732	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.319361	Pr > A-Sq >0.2500

**Forecasts for variable y**

Obs	Forecast	Std Error	95% Confidence Limits	
41	6.0622	1.3459	3.4242	8.7002
42	5.5227	1.3459	2.8847	8.1608
43	5.3965	1.3459	2.7585	8.0345
44	5.6855	1.3459	3.0475	8.3235

## Lampiran 5. Output Model ARIMA Produktivitas Alpakat (Lanjutan)

### c. Model ARIMA 3

#### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MU	5.00873	0.11655	42.97	<.0001	0
MA1,1	0.31605	0.15859	1.99	0.0537	2
AR1,1	-0.50185	0.21608	-2.32	0.0258	22

Constant Estimate 7.522362  
 Variance Estimate 1.703185  
 Std Error Estimate 1.305061  
 AIC 137.6966  
 SBC 142.7632  
 Number of Residuals 40

\* AIC and SBC do not include log determinant.

#### Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.97	4	0.9139	-0.021	0.002	-0.004	0.047	0.087	-0.099
12	6.25	10	0.7941	-0.056	-0.170	-0.192	-0.131	0.036	0.096
18	10.58	16	0.8348	-0.106	-0.191	-0.004	0.035	0.127	-0.011
24	13.67	22	0.9127	0.026	0.011	-0.048	-0.000	0.147	-0.080

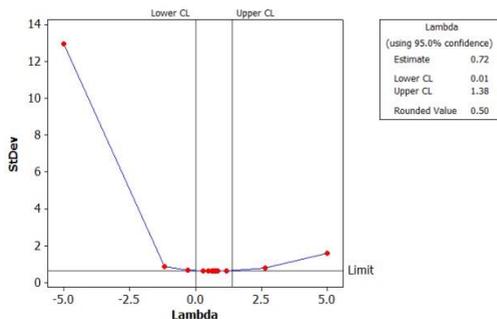
#### Tests for Normality

Test	--Statistic--	----p Value----		
Shapiro-Wilk	W 0.935433	Pr < W	0.0243	
Kolmogorov-Smirnov	D 0.110683	Pr > D	>0.1500	
Cramer-von Mises	W-Sq 0.091498	Pr > W-Sq	0.1437	
Anderson-Darling	A-Sq 0.622661	Pr > A-Sq	0.0983	

#### Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
41	6.5773	1.3051	4.0194	9.1351
42	5.1800	1.3051	2.6221	7.7378
43	5.4359	1.3687	2.7533	8.1185
44	5.7560	1.3687	3.0734	8.4386

## Lampiran 6. Output Model ARIMA Produktivitas Jambu Biji



## Lampiran 6. Output Model ARIMA Produktivitas Jambu Biji (Lanjutan)

### a. Model ARIMA 1

**Conditional Least Squares Estimation**

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MU	3.18448	0.28997	10.98	<.0001	0
AR1,1	0.42845	0.14865	2.88	0.0065	1

Constant Estimate      1.820093  
 Variance Estimate      1.149509  
 Std Error Estimate      1.072151  
 AIC                      121.0367  
 SBC                      124.4145  
 Number of Residuals      40  
 \* AIC and SBC do not include log determinant.

**Autocorrelation Check of Residuals**

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.63	5	0.7561	0.044	-0.073	-0.112	0.157	-0.107	-0.027
12	10.31	11	0.5026	-0.016	0.002	-0.300	0.034	0.114	0.181
18	12.82	17	0.7479	-0.173	0.065	-0.019	0.044	-0.004	-0.053
24	13.61	23	0.9375	-0.020	0.040	0.057	-0.040	-0.032	-0.028

**Tests for Normality**

Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W	0.965151	Pr < W    0.2502
Kolmogorov-Smirnov	D	0.128501	Pr > D    0.0936
Cramer-von Mises	W-Sq	0.111716	Pr > W-Sq 0.0793
Anderson-Darling	A-Sq	0.589697	Pr > A-Sq 0.1210

**Forecasts for variable y**

Obs	Forecast	Std Error	95% Confidence Limits	
41	3.6075	1.0722	1.5061	5.7088
42	3.3657	1.1664	1.0796	5.6518
43	3.2621	1.1829	0.9437	5.5806
44	3.2177	1.1859	0.8934	5.5421

### b. Model ARIMA 2

**Conditional Least Squares Estimation**

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MU	3.15072	0.23446	13.44	<.0001	0
MA1,1	-0.38621	0.15119	-2.55	0.0148	1

Constant Estimate      3.150718  
 Variance Estimate      1.164696  
 Std Error Estimate      1.079211  
 AIC                      121.5618  
 SBC                      124.9395  
 Number of Residuals      40  
 \* AIC and SBC do not include log determinant.

## Lampiran 6. Output Model ARIMA Produktivitas Jambu Biji (Lanjutan)

**Autocorrelation Check of Residuals**

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.29	5	0.6555	-0.071	0.109	-0.113	0.155	-0.132	-0.012
12	10.92	11	0.4504	-0.088	-0.007	-0.294	0.054	0.047	0.193
18	13.44	17	0.7060	-0.156	0.094	-0.043	0.051	-0.014	-0.040
24	14.07	23	0.9247	-0.015	0.027	0.047	-0.040	-0.027	-0.036

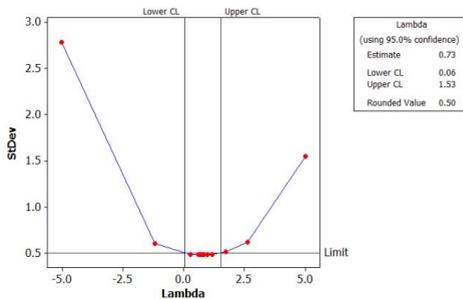
**Tests for Normality**

Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.958786	Pr < W	0.1522
Kolmogorov-Smirnov	D	0.158845	Pr > D	0.0120
Cramer-von Mises	W-Sq	0.16747	Pr > W-Sq	0.0142
Anderson-Darling	A-Sq	0.803932	Pr > A-Sq	0.0359

**Forecasts for variable y**

Obs	Forecast	Std Error	95% Confidence Limits	
41	3.5123	1.0792	1.3971	5.6275
42	3.1507	1.1569	0.8832	5.4182
43	3.1507	1.1569	0.8832	5.4182
44	3.1507	1.1569	0.8832	5.4182

## Lampiran 7. Output Model ARIMA Produktivitas Pisang



### a. Model ARIMA 1

**Conditional Least Squares Estimation**

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
AR1,1	-0.41664	0.15148	-2.75	0.0091	9
Variance Estimate			0.420915		
Std Error Estimate			0.648779		
AIC			77.91647		

**Autocorrelation Check of Residuals**

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.88	5	0.5670	-0.207	-0.092	-0.069	-0.116	0.021	0.133
12	9.80	11	0.5481	-0.176	0.094	-0.005	-0.033	-0.082	0.242
18	12.40	17	0.7754	-0.028	0.022	-0.095	0.090	-0.136	0.013
24	16.54	23	0.8312	-0.093	-0.036	0.136	0.106	-0.012	-0.077

## Lampiran 7. Output Model ARIMA Produktivitas Pisang (Lanjutan)

Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.981693	Pr < W 0.7644
Kolmogorov-Smirnov	D 0.113248	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.05833	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.343057	Pr > A-Sq >0.2500

Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
41	2.2459	0.6488	0.9743	3.5175
42	2.1693	0.9175	0.3710	3.9676
43	2.1007	1.1237	-0.1018	4.3031
44	2.2262	1.2976	-0.3170	4.7693

### b. Model ARIMA 2

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1,1	0.36697	0.16047	2.29	0.0279	9

Variance Estimate                      0.432336  
Std Error Estimate                    0.657523  
AIC    78.96067

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.77	5	0.4444	-0.244	-0.068	-0.082	-0.095	0.014	0.167
12	11.81	11	0.3782	-0.191	0.104	-0.058	0.009	-0.107	0.254
18	16.93	17	0.4590	-0.036	0.005	-0.103	0.097	-0.167	0.148
24	20.40	23	0.6175	-0.123	-0.039	0.114	0.089	-0.013	-0.044

Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.983529	Pr < W 0.8271
Kolmogorov-Smirnov	D 0.082988	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.049512	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.305257	Pr > A-Sq >0.2500

Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
41	2.2398	0.6575	0.9511	3.5285
42	2.1689	0.9299	0.3464	3.9915
43	2.1030	1.1389	-0.1291	4.3352
44	2.2355	1.3150	-0.3420	4.8129

## Lampiran 8. Output Model ARIMA Suhu Rata-rata

### a. Model ARIMA 1

**Conditional Least Squares Estimation**

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1,1	0.97388	0.08115	12.00	<.0001	4

Variance Estimate      1.007556  
 Std Error Estimate    1.003771  
 AIC                        100.5746  
 SBC                        102.1299  
 Number of Residuals    35  
 \* AIC and SBC do not include log determinant.

**Autocorrelation Check of Residuals**

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.04	5	0.5442	-0.185	-0.148	0.142	-0.102	-0.077	-0.091
12	6.94	11	0.8039	-0.030	0.078	0.074	-0.098	0.056	0.170
18	10.77	17	0.8685	-0.114	0.011	0.013	-0.203	0.007	-0.053
24	14.13	23	0.9231	0.034	0.076	0.137	-0.063	0.014	-0.073

**Tests for Normality**

Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.89125	Pr < W	0.0023
Kolmogorov-Smirnov	D	0.131458	Pr > D	0.1269
Cramer-von Mises	W-Sq	0.138609	Pr > W-Sq	0.0334
Anderson-Darling	A-Sq	0.955687	Pr > A-Sq	0.0153

### b. Model ARIMA 2

**Conditional Least Squares Estimation**

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
AR1,1	-0.72905	0.14518	-5.02	<.0001	4

Variance Estimate      1.237818  
 Std Error Estimate    1.112572  
 AIC                        107.7784  
 SBC                        109.3337  
 Number of Residuals    35  
 \* AIC and SBC do not include log determinant.

**Autocorrelation Check of Residuals**

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.60	5	0.4665	-0.183	-0.093	0.172	-0.195	-0.041	-0.053
12	6.23	11	0.8576	0.030	-0.041	0.087	-0.020	0.090	0.110
18	12.07	17	0.7951	-0.175	0.119	0.004	-0.206	-0.057	0.002
24	15.13	23	0.8900	0.044	0.010	0.139	-0.003	0.017	-0.095

**Tests for Normality**

Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.85204	Pr < W	0.0003
Kolmogorov-Smirnov	D	0.12211	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.136047	Pr > W-Sq	0.0364
Anderson-Darling	A-Sq	0.977662	Pr > A-Sq	0.0132

## Lampiran 8. Output Model ARIMA Suhu Rata-rata (Lanjutan)

Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
41	19.2806	1.1126	17.1000	21.4613
42	19.4318	1.5734	16.3480	22.5157
43	18.5212	1.9270	14.7443	22.2981
44	19.6134	2.2251	15.2522	23.9746

### c. Model ARIMA 3

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
AR1,1	-0.97762	0.15927	-6.14	<.0001	4
AR1,2	-0.72269	0.25739	-2.81	0.0083	8

Variance Estimate 1.029402  
 Std Error Estimate 1.014595  
 AIC 102.2805  
 SBC 105.3912  
 Number of Residuals 35

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.31	4	0.3662	-0.196	-0.185	0.084	0.109	-0.083	-0.097
12	6.09	10	0.8077	-0.091	-0.040	-0.046	0.030	0.134	-0.060
18	15.40	16	0.4957	-0.163	0.064	0.167	-0.283	0.008	0.055
24	19.80	22	0.5956	0.055	-0.033	0.130	0.067	-0.091	-0.100

Tests for Normality

Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W 0.863333	Pr < W	0.0005
Kolmogorov-Smirnov	D 0.148066	Pr > D	0.0497
Cramer-von Mises	W-Sq 0.111466	Pr > W-Sq	0.0794
Anderson-Darling	A-Sq 0.918248	Pr > A-Sq	0.0188

Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
41	22.5162	1.0146	20.5276	24.5048
42	22.2605	1.4349	19.4482	25.0728
43	21.4558	1.7573	18.0115	24.9001
44	23.5763	2.0292	19.5992	27.5535

## Lampiran 9. Output Model ARIMA Kelembaban

### a. Model ARIMA 1

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1,1	0.70312	0.14663	4.80	<.0001	4

Variance Estimate 20.30581  
 Std Error Estimate 4.506196  
 AIC 205.6929  
 SBC 207.2482  
 Number of Residuals 35

\* AIC and SBC do not include log determinant.

## Lampiran 9. Output Model ARIMA Kelembaban (Lanjutan)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.48	5	0.4819	0.039	-0.166	-0.261	-0.005	-0.026	0.112
12	11.63	11	0.3921	0.025	-0.097	-0.213	0.052	0.263	0.098
18	17.89	17	0.3961	0.077	-0.073	-0.164	0.012	0.212	-0.089
24	27.35	23	0.2413	-0.070	-0.118	0.010	0.015	0.117	0.232

### Tests for Normality

Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.953749	Pr < W	0.1477
Kolmogorov-Smirnov	D	0.102319	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.051172	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.363584	Pr > A-Sq	>0.2500

### Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
41	97.8315	4.5062	88.9996	106.6635
42	96.4104	6.3727	83.9201	108.9007
43	93.8406	7.8050	78.5432	109.1380
44	95.4083	9.0124	77.7444	113.0723

## b. Model ARIMA 2

### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
AR1,1	-0.48647	0.16140	-3.01	0.0048	4

Variance Estimate            23.88931  
 Std Error Estimate        4.887669  
 AIC                            211.3812  
 SBC                            212.9366  
 Number of Residuals        35  
 \* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.41	5	0.1350	0.133	-0.202	-0.311	-0.150	0.007	0.170
12	24.05	11	0.0125	0.059	-0.275	-0.278	0.177	0.322	0.117
18	31.27	17	0.0185	0.031	-0.076	-0.203	-0.013	0.228	-0.072
24	41.06	23	0.0117	-0.120	-0.151	-0.004	0.070	0.122	0.197

### Tests for Normality

Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.937773	Pr < W	0.0479
Kolmogorov-Smirnov	D	0.131116	Pr > D	0.1293
Cramer-von Mises	W-Sq	0.079198	Pr > W-Sq	0.2128
Anderson-Darling	A-Sq	0.505259	Pr > A-Sq	0.1983

## c. Model ARIMA 3

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.94	4	0.5687	-0.084	-0.181	-0.113	-0.032	-0.077	0.112
12	8.61	10	0.5693	0.018	-0.014	-0.156	0.107	0.199	-0.174
18	12.21	16	0.7291	0.083	0.072	-0.120	0.002	0.126	-0.102
24	20.58	22	0.5465	-0.043	-0.093	0.049	-0.004	0.071	0.239

## Lampiran 9. Output Model ARIMA Kelembaban (Lanjutan)

### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
ARI,1	-0.62797	0.15861	-3.96	0.0004	4
ARI,2	-0.55804	0.21334	-2.62	0.0133	8

Variance Estimate	20.38639
Std Error Estimate	4.515129
AIC	206.7866
SBC	209.8973
Number of Residuals	35

### Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.958444	Pr < W 0.2053
Kolmogorov-Smirnov	D 0.11881	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.060234	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.376706	Pr > A-Sq >0.2500

## Lampiran 10. Output Model ARIMA Curah Hujan

### a. Model ARIMA 1

#### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1,1	0.38510	0.12778	3.01	0.0049	1
MA1,2	0.61490	0.13297	4.62	<.0001	4

Variance Estimate	81543.72
Std Error Estimate	285.5586
AIC	497.0776
SBC	500.1883
Number of Residuals	35

\* AIC and SBC do not include log determinant.

#### Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	10.99	4	0.0266	-0.131	-0.209	-0.179	-0.231	0.326	0.106
12	15.11	10	0.1280	0.039	-0.132	-0.099	0.185	-0.132	0.015
18	19.48	16	0.2447	0.163	0.038	-0.009	-0.035	-0.191	0.013
24	27.52	22	0.1922	0.220	0.049	0.009	-0.183	-0.038	0.060

### Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.936316	Pr < W 0.0433
Kolmogorov-Smirnov	D 0.1106958	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.079878	Pr > W-Sq 0.2087
Anderson-Darling	A-Sq 0.547499	Pr > A-Sq 0.1508

#### Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
41	733.7003	285.5586	174.0157	1293.3849
42	279.6204	335.2246	-377.4077	936.6485
43	-40.6969	378.4274	-782.4010	701.0072
44	540.0000	417.1799	-277.6577	1357.6577

## Lampiran 10. Output Model ARIMA Curah Hujan (Lanjutan)

### b. Model ARIMA 2

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag				
AR1,1	-0.32543	0.13718	-2.37	0.0237	1				
AR1,2	-0.50299	0.13969	-3.60	0.0010	4				
Variance Estimate			90803.78						
Std Error Estimate			301.3367						
AIC			500.8422						
SBC			503.9529						
Number of Residuals			35						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.42	4	0.0513	-0.126	-0.316	-0.008	-0.178	-0.056	0.277
12	20.60	10	0.0241	0.143	-0.368	0.012	0.165	-0.182	0.098
18	25.76	16	0.0575	0.180	-0.015	-0.086	0.036	-0.166	-0.095
24	32.90	22	0.0632	0.251	0.037	-0.036	-0.120	-0.046	0.035
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.969737	Pr < W	0.4361					
Kolmogorov-Smirnov	D	0.109928	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.042784	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.279889	Pr > A-Sq	>0.2500					
Forecasts for variable y									
Obs	Forecast	Std Error	95% Confidence Limits						
41	882.8033	301.3367	292.1943	1473.4123					
42	301.8971	363.4887	-410.5277	1014.3219					
43	49.8598	432.9394	-798.6858	898.4054					
44	663.6566	487.8237	-292.4604	1619.7736					

### c. Model ARIMA 3

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag				
MA1,1	0.92425	0.07021	13.16	<.0001	1				
AR1,1	-0.53647	0.15198	-3.53	0.0012	4				
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.67	4	0.2250	0.132	-0.129	-0.156	-0.206	0.099	0.162
12	12.93	10	0.2276	0.113	-0.263	-0.081	0.135	-0.030	0.190
18	18.77	16	0.2807	0.208	0.085	-0.039	-0.067	-0.166	-0.078
24	24.38	22	0.3276	0.184	0.073	-0.012	-0.112	-0.013	0.097
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.983499	Pr < W	0.8654					
Kolmogorov-Smirnov	D	0.095147	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.039264	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.241122	Pr > A-Sq	>0.2500					

## Lampiran 11. Output Model Fungsi Transfer Produktivitas Apel dengan Deret Input Suhu Rata-rata

### a. Estimasi Parameter

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.59494	0.18018	3.30	0.0024	4	y	0
AR1,1	-0.50328	0.18825	-2.67	0.0119	4	y	0
NUM1	0.33940	0.44018	0.77	0.4465	0	x	1
Variance Estimate				6.911877			
Std Error Estimate				2.629045			
AIC				155.0773			
SBC				159.6564			
Number of Residuals				34			
* AIC and SBC do not include log determinant.							

## Lampiran 12. Output Model Fungsi Transfer Produktivitas Apel dengan Deret Input Kelembaban

### a. Estimasi Parameter

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.56726	0.19437	2.92	0.0082	4	y	0
NUM1	0.24694	0.13558	1.82	0.0828	0	x	3
NUM1,1	-0.39793	0.17288	-2.30	0.0317	8	x	3
Variance Estimate				9.611497			
Std Error Estimate				3.100241			
AIC				125.2153			
SBC				128.7495			
Number of Residuals				24			
* AIC and SBC do not include log determinant.							

### b. Uji Asumsi Residual *White Noise*

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.04	5	0.5492	0.209	0.082	0.235	-0.068	-0.162	0.026
12	8.56	11	0.6628	0.028	0.015	0.238	-0.029	0.083	0.183
18	13.00	17	0.7365	-0.016	-0.173	0.046	-0.077	-0.146	0.020

### c. Uji Asumsi Residual Berdistribusi Normal

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.950102	Pr < W	0.2723
Kolmogorov-Smirnov	D	0.134184	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.070712	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.451767	Pr > A-Sq	>0.2500

### d. Peramalan data *testing*

41	7.4191	3.1002	1.3428	13.4955
42	10.0743	4.3844	1.4811	18.6676
43	9.5157	5.3698	-1.0088	20.0403
44	14.5275	6.2999	2.1799	26.8751

## Lampiran 13. Output Model Fungsi Transfer Produktivitas Apel dengan Deret Input Curah Hujan

### a. Estimasi Parameter

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.53309	0.20846	2.56	0.0160	4	y	0
AR1,1	-0.57801	0.19003	-3.05	0.0048	4	y	0
NUM1	0.0048276	0.0012597	3.83	0.0006	0	x	3

Variance Estimate      4.532918  
 Std Error Estimate    2.129065  
 AIC                      142.0257  
 SBC                      146.4229  
 Number of Residuals    32  
 \* AIC and SBC do not include log determinant.

### b. Uji Asumsi Residual *White Noise*

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.25	4	0.2628	0.066	-0.206	0.140	-0.022	-0.203	0.166
12	7.44	10	0.6832	0.083	-0.006	0.175	0.085	0.038	0.011
18	8.72	16	0.9244	0.006	0.127	-0.032	0.000	0.055	0.015
24	19.72	22	0.6007	-0.017	0.205	-0.088	-0.152	0.120	0.126

### c. Uji Asumsi Residual Berdistribusi Normal

Tests for Normality

Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.968629	Pr < W	0.4624
Kolmogorov-Smirnov	D	0.139486	Pr > D	0.1118
Cramer-von Mises	W-Sq	0.087816	Pr > W-Sq	0.1607
Anderson-Darling	A-Sq	0.490992	Pr > A-Sq	0.2131

### d. Peramalan data *testing*

40	5.0120	4.1251	1.8869	10.0101
41	5.1601	2.1291	0.9872	9.3330
42	4.3178	3.0110	-1.5836	10.2192
43	5.3956	3.6876	-1.8321	12.6232
44	5.6344	4.4351	-3.0583	14.3271

## Lampiran 14. Output Model Fungsi Transfer Produktivitas Jeruk dengan Deret Input Suhu Rata-rata

### a. Estimasi Parameter

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	-0.56029	0.17735	-3.16	0.0042	4	y	0
NUM1	-4.19780	1.99283	-2.11	0.0458	0	x	4
NUM1,1	9.06127	3.09372	2.93	0.0073	4	x	4

Variance Estimate      122.9217  
 Std Error Estimate    11.08701  
 AIC                      209.3543  
 SBC                      213.2418  
 Number of Residuals    27  
 \* AIC and SBC do not include log determinant.

## Lampiran 14. Output Model Fungsi Transfer Produktivitas Jeruk dengan Deret Input Suhu Rata-rata (Lanjutan)

### b. Uji Asumsi Residual *White Noise*

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.10	5	0.2963	-0.210	-0.271	-0.042	-0.003	0.258	-0.037
12	12.30	11	0.2998	-0.006	-0.156	0.042	0.132	0.096	-0.293
18	14.01	17	0.6655	0.053	0.033	-0.035	0.029	-0.017	0.089
24	21.75	23	0.5352	-0.214	0.106	-0.012	-0.061	0.069	-0.043

### c. Uji Asumsi Residual Berdistribusi Normal

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.987793	Pr < W	0.9824
Kolmogorov-Smirnov	D	0.078015	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.026283	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.17674	Pr > A-Sq	>0.2500

### d. Peramalan data *testing*

41	50.9085	11.0870	29.1784	72.6387
42	64.4449	15.6794	33.7139	95.1760
43	62.7914	19.2033	25.1537	100.4291
44	60.4494	22.1740	16.9891	103.9097

## Lampiran 15. Output Model Fungsi Transfer Produktivitas Alpukat dengan Deret Input Suhu Rata-rata

### a. Estimasi Parameter

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
ARI,1	-0.46104	0.20344	-2.27	0.0341	4	y	0
NUM1	9.40354	4.44573	2.12	0.0465	0	x	5
NUM1,1	-18.52907	7.23481	-2.56	0.0182	5	x	6
Variance Estimate				817.1842			
Std Error Estimate				28.58643			
AIC				231.845			
SBC				235.3792			
Number of Residuals				24			
* AIC and SBC do not include log determinant.							

### b. Uji Asumsi Residual *White Noise*

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.71	5	0.3357	-0.351	-0.100	0.190	-0.120	-0.066	0.110
12	14.46	11	0.2088	0.218	-0.302	-0.031	0.210	-0.161	-0.062
18	21.00	17	0.2262	0.163	-0.174	-0.004	0.068	0.135	-0.105

### c. Uji Asumsi Residual Berdistribusi Normal

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.975581	Pr < W	0.8027
Kolmogorov-Smirnov	D	0.094689	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.039015	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.276042	Pr > A-Sq	>0.2500

**Lampiran 15. Output Model Fungsi Transfer Produktivitas Alpukat dengan Deret Input Suhu Rata-rata (Lanjutan)**

d. Peramalan data *testing*

41	53.6514	28.5864	-2.3770	109.6797
42	47.4967	40.4273	-31.7394	126.7328
43	62.4644	49.5132	-34.5796	159.5084
44	-2.5987	57.1729	-114.6555	109.4580

**Lampiran 16. Output Model Fungsi Transfer Produktivitas Alpukat dengan Deret Input Kelembaban**

a. Estimasi Parameter

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.84174	0.12635	6.66	<.0001	4	y	0
AR1,1	-0.71715	0.19422	-3.69	0.0010	1	y	0
AR1,2	-0.41375	0.13105	-2.20	0.0371	2	y	0
NUM1	1.63916	0.71592	2.29	0.0304	0	x	3
NUM1,1	1.61577	0.68638	2.35	0.0254	1	x	3

b. Uji Asumsi Residual *White Noise*

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.95	3	0.8123	-0.018	-0.042	-0.012	-0.004	0.046	-0.139
12	3.91	9	0.9171	0.037	-0.117	0.011	-0.060	0.172	0.105
18	8.41	15	0.3065	0.059	0.086	0.074	0.128	0.077	0.143
24	17.75	21	0.6646	-0.196	-0.055	-0.071	-0.055	0.170	-0.091

c. Uji Asumsi Residual Berdistribusi Normal

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.918382	Pr < W	0.0214
Kolmogorov-Smirnov	D	0.156136	Pr > D	0.0522
Cramer-von Mises	W-Sq	0.132992	Pr > W-Sq	0.0396
Anderson-Darling	A-Sq	0.810335	Pr > A-Sq	0.0335

d. Peramalan data *testing*

41	36.1241	19.6938	-2.4750	74.7232
42	29.8555	20.4664	-10.2579	69.9689
43	25.0028	21.7742	-17.6738	67.6794
44	32.5074	25.9519	-18.3573	83.3722

**Lampiran 17. Output Model Fungsi Transfer Produktivitas Alpukat dengan Deret Input Curah Hujan**

a. Estimasi Parameter

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.81684	0.14864	5.50	<.0001	4	y	0
AR1,1	-0.66219	0.20688	-3.20	0.0035	1	y	0
AR1,2	-0.45335	0.20369	-2.23	0.0346	2	y	0
NUM1	-0.03339	0.01363	-2.45	0.0211	0	x	4

## Lampiran 17. Output Model Fungsi Transfer Produktivitas Alpukat dengan Deret Input Curah Hujan (Lanjutan)

### b. Uji Asumsi Residual *White Noise*

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.69	3	0.8756	-0.047	-0.057	-0.113	0.005	0.004	0.027
12	6.16	9	0.7239	-0.057	-0.210	-0.045	0.114	0.187	0.126
18	12.19	15	0.6647	-0.067	0.005	-0.046	0.229	0.168	-0.015
24	20.76	21	0.4739	-0.107	-0.036	-0.007	-0.084	0.160	-0.153

### c. Uji Asumsi Residual Berdistribusi Normal

Tests for Normality

Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W 0.957665	Pr < W	0.2528
Kolmogorov-Smirnov	D 0.141908	Pr > D	0.1098
Cramer-von Mises	W-Sq 0.10436	Pr > W-Sq	0.0954
Anderson-Darling	A-Sq 0.556606	Pr > A-Sq	0.1426

### d. Peramalan data *testing*

41	36.4663	19.7355	-2.2145	75.1472
42	23.9910	20.8312	-16.8374	64.8193
43	39.7951	21.7844	-2.9015	82.4918
44	43.8362	25.1122	-5.3828	93.0553

## Lampiran 18. Output Model Fungsi Transfer Produktivitas Jambu Biji dengan Deret Input Suhu Rata-rata

### a. Estimasi Parameter

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.98253	0.09904	9.92	<.0001	4	y	0
NUM1	-2.01428	1.10363	-1.83	0.0791	0	x	1
NUM1,1	1.32918	1.14147	1.16	0.2544	4	x	1

Variance Estimate 39.23603  
 Std Error Estimate 6.263861  
 AIC 199.0634  
 SBC 202.267  
 Number of Residuals 30  
 \* AIC and SBC do not include log determinant.

## Lampiran 19. Output Model Fungsi Transfer Produktivitas Jambu Biji dengan Deret Input Kelembaban

### a. Estimasi Parameter

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.95267	0.08032	11.86	<.0001	4	y	0
NUM1	0.59356	0.21720	2.73	0.0104	0	x	3

Variance Estimate 37.92593  
 Std Error Estimate 6.158403  
 AIC 209.0872  
 SBC 212.0186  
 Number of Residuals 32  
 \* AIC and SBC do not include log determinant.

## Lampiran 19. Output Model Fungsi Transfer Produktivitas Jambu Biji dengan Deret Input Kelembaban (Lanjutan)

### b. Uji Asumsi Residual *White Noise*

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.55	5	0.2563	-0.221	-0.258	-0.077	0.219	-0.092	0.007
12	7.56	11	0.7517	-0.006	0.031	-0.055	0.085	-0.076	-0.054
18	10.70	17	0.8718	0.147	-0.028	0.031	-0.122	0.019	0.098
24	19.96	23	0.6446	-0.072	-0.006	0.154	0.044	-0.213	-0.075

### c. Uji Asumsi Residual Berdistribusi Normal

Tests for Normality

Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.953608	Pr < W	0.1823
Kolmogorov-Smirnov	D	0.155305	Pr > D	0.0478
Cramer-von Mises	W-Sq	0.087658	Pr > W-Sq	0.1616
Anderson-Darling	A-Sq	0.549219	Pr > A-Sq	0.1484

### d. Peramalan data *testing*

40	15.7227	6.1584	3.6525	27.7930
41	21.7584	6.1584	9.6881	33.8286
42	23.6108	8.7093	6.5409	40.6807
43	19.9147	10.6667	-0.9916	40.8210
44	20.6973	12.6050	-4.0080	45.4027

## Lampiran 20. Output Model Fungsi Transfer Produktivitas Jambu Biji dengan Deret Input Curah Hujan

### a. Estimasi Parameter

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
ARI_1	-0.49288	0.17641	-2.79	0.0091	2	y	0
ARI_2	-0.53241	0.17633	-3.02	0.0052	4	y	0
NUM1	0.01209	0.0028513	4.24	0.0002	0	x	3

Variance Estimate                    31.48146  
 Std Error Estimate                5.610834  
 AIC                                        204.0427  
 SBC                                        208.4399  
 Number of Residuals                32  
 \* AIC and SBC do not include log determinant.

### b. Uji Asumsi Residual *White Noise*

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.93	4	0.4162	-0.293	0.021	-0.039	0.003	-0.090	0.111
12	11.68	10	0.3068	-0.043	-0.040	-0.242	0.079	0.072	-0.280
18	18.57	16	0.2918	0.201	-0.086	0.209	-0.127	0.057	-0.001
24	29.12	22	0.1416	-0.087	0.000	0.265	-0.164	-0.003	-0.016

### c. Uji Asumsi Residual Berdistribusi Normal

Tests for Normality

Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.970908	Pr < W	0.5248
Kolmogorov-Smirnov	D	0.112726	Pr > D	> 0.1500
Cramer-von Mises	W-Sq	0.067344	Pr > W-Sq	> 0.2500
Anderson-Darling	A-Sq	0.386898	Pr > A-Sq	> 0.2500

**Lampiran 20. Output Model Fungsi Transfer Produktivitas Jambu Biji dengan Deret Input Curah Hujan (Lanjutan)**

**d. Peramalan data *testing***

40	13.8084	5.6108	2.8114	24.8054
41	16.2749	5.6108	5.2779	27.2720
42	14.2571	7.9349	-1.2951	29.8092
43	14.2716	8.4297	-2.2502	30.7935
44	15.6338	9.4234	-2.8358	34.1034

**Lampiran 21. Output Model FFNN Produktivitas Apel**

**Model Summary**

Training	Sum of Squares Error	3.241
	Relative Error	.216
	Stopping Rule Used	1 consecutive step(s) with no decrease in error <sup>a</sup>
	Training Time	00:00:00.000
Testing	Sum of Squares Error	.009
	Relative Error	.043

Dependent Variable: Yt

a. Error computations are based on the testing sample.

**Parameter Estimates**

Predictor		Predicted		
		Hidden Layer 1		Output Layer
		H(1:1)	H(1:2)	Yt
Input Layer	(Bias)	-2.559	-.990	
	Ytmin1	1.635	-.136	
	Ytmin4	-.990	.264	
	Ytmin5	-1.523	-1.408	
	Ytmin8	.272	.326	
	Ytmin9	-.598	-.774	
	Xtmin3	.135	-.390	
	Xtmin4	.062	.927	
	Xtmin7	.507	.813	
Hidden Layer 1	Xtmin8	.984	-.564	
	(Bias)			-.119
	H(1:1)			3.263
	H(1:2)			-1.849



## Lampiran 23. Output Model FFNN Produktivitas Alpukat

### Model Summary

Training	Sum of Squares Error	12.844
	Relative Error	.856
	Stopping Rule Used	1 consecutive step(s) with no decrease in error <sup>a</sup>
	Training Time	00:00:00.000
Testing	Sum of Squares Error	.870
	Relative Error	.556

Dependent Variable: Yt

a. Error computations are based on the testing sample.

### Parameter Estimates

Predictor		Predicted	
		Hidden Layer 1	Output Layer
		H(1:1)	Yt
Input Layer	(Bias)	-.512	
	Ytmin1	.226	
	Ytmin2	.363	
	Ytmin3	-.143	
	Ytmin4	.491	
	Ytmin5	.144	
	Ytmin6	-.192	
	Ytmin7	.016	
	Xtmin4	.138	
Hidden Layer 1	Xtmin5	.127	
	Xtmin8	-.474	
	Xtmin9	.141	
	(Bias)		1.180
	H(1:1)		-2.794

## Lampiran 24. Output Model FFNN Produktivitas Jambu biji

### Model Summary

Training	Sum of Squares Error	13.375
	Relative Error	.955
	Stopping Rule Used	1 consecutive step(s) with no decrease in error <sup>a</sup>
	Training Time	00:00:00.015
Testing	Sum of Squares Error	.341
	Relative Error	1.082

Dependent Variable: Yt

a. Error computations are based on the testing sample.

### Parameter Estimates

Predictor	Predicted					
	Hidden Layer 1				Output Layer	
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	Yt	
Input Layer	(Bias)	.208	-.373	.247	.168	
	Ytmin1	.110	.082	.051	.158	
	Ytmin2	.305	-.464	.251	-.670	
	Ytmin3	-.150	.383	.021	.076	
	Ytmin4	-.634	.188	.222	.670	
	Ytmin5	.425	.102	-.376	-.169	
	Ytmin6	.143	-.299	.678	.049	
	Ytmin7	-.196	-.060	.601	-.507	
	Ytmin8	-.242	-.068	.366	.445	
	Ytmin9	-.218	.433	-.372	-.197	
	Ytmin10	-.612	-.258	.155	.381	
Ytmin11	.614	.213	-.365	.189		
Hidden Layer 1	Xtmin3	-.041	.145	.189	-.392	
	Xtmin4	.543	-.083	-.367	.103	
	Xtmin7	.580	-.218	.451	.204	
	Xtmin8	.112	-.044	-.480	.243	
	(Bias)					-.391
	H(1:1)					-.281
	H(1:2)					.084
	H(1:3)					.450
H(1:4)					.669	

## Lampiran 25. Output Model FFNN Produktivitas Pisang

### Model Summary

Training	Sum of Squares Error	13.010
	Relative Error	.897
	Stopping Rule Used	1 consecutive step(s) with no decrease in error <sup>a</sup>
	Training Time	00:00:00.015
Testing	Sum of Squares Error	.312
	Relative Error	1.950

Dependent Variable: Yt

a. Error computations are based on the testing sample.

### Parameter Estimates

Predictor		Predicted					Yt	
		Hidden Layer 1						Output Layer
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)		
Input Layer	(Bias)	-.025	-.010	-.242	.118	-.446		
	Ytmin1	-.625	.271	-.311	1.225	.003		
	Ytmin9	1.256	-.446	-.214	-1.442	.423		
	Ytmin10	.738	-.217	-.179	-.052	-.269		
Hidden Layer 1	(Bias)						.751	
	H(1:1)						-.555	
	H(1:2)						-2.042	
	H(1:3)						-2.092	
	H(1:4)						2.757	
	H(1:5)						.118	

## Lampiran 26. Hasil Peramalan Deret Input Suhu

### Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
45	21.9406	0.9742	20.0313	23.8499
46	21.6562	1.3777	18.9560	24.3563
47	20.8934	1.6873	17.5864	24.2005
48	22.6801	1.9483	18.8615	26.4988

**Lampiran 26.** Hasil Peramalan Deret Input (Lanjutan)  
Kelembaban

Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
45	100.8782	4.3659	92.3213	109.4352
46	100.2230	6.1743	88.1216	112.3243
47	98.5015	7.5619	83.6805	113.3226
48	95.5190	8.7318	78.4051	112.6329

Curah Hujan

Forecasts for variable y

Obs	Forecast	Std Error	95% Confidence Limits	
45	777.2356	254.0800	279.2479	1275.2233
46	193.0403	254.5950	-305.9566	692.0373
47	-32.1247	255.1089	-532.1290	467.8795
48	443.9393	255.6218	-57.0701	944.9488

**Lampiran 27.** Syntax Model Curah Hujan ARIMA (0,1,1)(1,1,0)<sup>4</sup>

```

data Ch;
input y;
datalines;
1026
178
28
605
937
.....
;
proc arima data=Ch;
identify var=y(1,4);
estimate
p=(4) q=(1) noconstant plot;
forecast out=ramalan lead=4;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;

```

**Lampiran 28.** Syntax Model Produktivitas Apel  
ARIMA (0,1,0)(1,0,0)<sup>4</sup>

```
data apel;
input y;
datalines;
4.81
4.33
1.25
1.28
1.27
...
;
proc arima data=apel;
identify var=y(1);
estimate
p=(4) q=(0) noconstant plot;
forecast out=ramalan lead=4;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

**Lampiran 29.** Syntax Model Fungsi Transfer Produktivitas Jambu Biji dengan Deret Input Suhu  $b,r,s$  ( $b=[3],r=0,s=0$ ) Deret Noise ARMA([2],0)(1,0)<sup>4</sup>

```

data batu;
  input x y;
  label x = 'Curah Hujan'
        y = 'Jambu Biji';
datalines;
1026  20.61
178   20.61
28    29
605   0.87
937   0.87
...
;
proc arima data=batu;
  /*--- Look at the input process -----*/
  identify var=x(1,4);
  run;
  /*--- Fit a model for the input -----*/
  estimate p=(4) q=(1) noconstant plot;
  run;
  /*--- Cross-correlation of prewhitened series -----*/
  identify var=y(1,4) crosscorr=(x(1,4)) nlag=12;
  run;
  /*--- Fit a simple transfer function - look at residuals ---*/
  estimate p=(2,4) q=(0) input=( 3 $ (0)/(0) x ) noconstant plot;
  run;
  forecast out=ramalan lead=4 printall;
  run;
  /*--- Cek Asumsi Normalitas Residual -----*/
  proc univariate data=ramalan normal plot;
  var residual;
  run;

```

### Lampiran 30. Hasil Uji Linieritas dengan *White Test*

```
> set.seed(1234)
> library(tseries)
> data=read.csv("D:/ApelCH.csv",header=TRUE)
> y=data$Apel
> x1=data$x1
> x2=data$x2
> x3=data$x3
> x4=data$x4
> x5=data$x5
...
> x9=data$x9
> x=cbind(x1,x2,x3,x4,x5,x6,x7,x8,x9)
> white.test(x,y,type=c("F"))
      White Neural Network Test
data: x and y
F = 0.69298, df1 = 2, df2 = 24, p-value = 0.5098

> set.seed(1234)
> library(tseries)
> data=read.csv("D:/Jeruksuhu.csv",header=TRUE)
> y=data$Jeruk
> x1=data$x1
> x2=data$x2
> x3=data$x3
> x4=data$x4
> x5=data$x5
...
> x11=data$x11
> x=cbind(x1,x2,x3,x4,x5,x6,x7,x8,x9,x10,x11)
> white.test(x,y,type=c("F"))
      White Neural Network Test
data: x and y
F = 0.57517, df1 = 2, df2 = 21, p-value = 0.5712
```

### Lampiran 30. Hasil Uji Linieritas dengan *White Test* (Lanjutan)

```
> set.seed(1234)
> library(tseries)
> data=read.csv("D:/AlpukatCH.csv",header=TRUE)
> y=data$Alpukat
> x1=data$x1
> x2=data$x2
> x3=data$x3
> x4=data$x4
> x5=data$x5
...
> x11=data$x11
> x=cbind(x1,x2,x3,x4,x5,x6,x7,x8,x9,x10,x11)
> white.test(x,y,type=c("F"))
      White Neural Network Test
data: x and y
F = 1.1511, df1 = 2, df2 = 22, p-value = 0.3346

> set.seed(1234)
> library(tseries)
> data=read.csv("D:/JambuCH.csv",header=TRUE)
> y=data$Jambu.Biji
> x1=data$x1
> x2=data$x2
> x3=data$x3
> x4=data$x4
> x5=data$x5
...
> x15=data$x15
> x=cbind(x1,x2,x3,x4,x5,x6,x7,x8,x9,x10,x11,x12,x13,x14,x15)
> white.test(x,y,type=c("F"))
      White Neural Network Test
data: x and y
F = 0.83386, df1 = 2, df2 = 16, p-value = 0.4524
```

### Lampiran 30. Hasil Uji Linieritas dengan *White Test* (Lanjutan)

```
> set.seed(1234)
> library(tseries)
> data=read.csv("D:/Pisang.csv",header=TRUE)
> y=data$Pisang
> x1=data$x1
> x2=data$x2
> x3=data$x3
> x=cbind(x1,x2,x3)
> white.test(x,y,type=c("F"))
```

White Neural Network Test

data: x and y

F = 0.78828, df1 = 2, df2 = 29, p-value = 0.4641

## Lampiran 31. Surat Keterangan Pengambilan Data di BMKG Karangploso Malang

### SURAT KETERANGAN

Saya yang bertanda tangan di bawah ini menerangkan bahwa :

1. Mahasiswa Statistika FMKSD-ITS dengan identitas berikut :

Nama : Indana Lazulfa Setyobudi

NRP : 06211745000010

Telah mengambil data di instansi/perusahaan kami :

Nama Instansi : BMKG Stasiun Klimatologi Malang

Divisi/ bagian : Pelayanan Data

sejak tanggal 12 Februari 2019 sampai dengan 30 April 2019 untuk  
keperluan Tugas Akhir/~~Thesis~~ Semester ~~Gasa/~~Genap\* 2018/2019.

2. Tidak Keberatan/~~Keberatan~~\* nama perusahaan dicantumkan dalam Tugas Akhir/~~Thesis~~ mahasiswa Statistika yang akan di simpan di Perpustakaan ITS dan dibaca di lingkungan ITS.
3. Tidak Keberatan/~~Keberatan~~\* bahwa hasil analisis data dari perusahaan dipublikasikan dalam E journal ITS yaitu Jurnal Sains dan Seni ITS.

Batu, 3 Juli 2019



(Edythy Ferlani W)

\*(coret yang tidak perlu)

**Lampiran 32. Surat Keterangan Pengambilan Data di Dinas  
Pertanian Kota Batu**

**SURAT KETERANGAN**

Saya yang bertanda tangan di bawah ini menerangkan bahwa :

1. Mahasiswa Statistika FMKSD-ITS dengan identitas berikut :

Nama : Indana Lazulfa Setyobudi

NRP : 06211745000010

Telah mengambil data di instansi/perusahaan kami :

Nama Instansi : Dinas Pertanian Kota Batu

Divisi/ bagian : Bidang Penyuluhan

sejak tanggal 12 Februari 2019 sampai dengan 30 April 2019 untuk keperluan Tugas Akhir/~~Thesis~~ Semester ~~Gesal~~ Genap\* 2018/2019.

2. Tidak Keberatan/~~Keberatan~~\* nama perusahaan dicantumkan dalam Tugas Akhir/ ~~Thesis~~ mahasiswa Statistika yang akan di simpan di Perpustakaan ITS dan dibaca di lingkungan ITS.
3. Tidak Keberatan/~~Keberatan~~\* bahwa hasil analisis data dari perusahaan dipublikasikan dalam E journal ITS yaitu Jurnal Sains dan Seni ITS.

Batu, 3 Juli 2019  
Kepala Bidang Penyuluhan



(HARIJADI AGUNG SETIJANA, S.TP, MM.)  
NIP. 19690227 199403 1 006

\*(coret yang tidak perlu)

**Lampiran 33.** Surat Pernyataan Pengambilan Data Melalui Publikasi BPS Kota Batu

**SURAT PERNYATAAN**

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FMKSD ITS:

Nama : Indana Lazulfa Setyobudi

NRP : 06211745000010

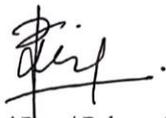
menyatakan bahwa data yang digunakan dalam Tugas Akhir/~~Thesis~~ ini merupakan data sekunder yang diambil dari ~~penelitian / buku/ Tugas Akhir/ Thesis/~~ publikasi lainnya yaitu:

Sumber : Publikasi BPS Kota Batu

Keterangan : Kota Batu Dalam Angka Tahun 2008-2018

Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Mengetahui  
Pembimbing Tugas Akhir



(Santi Puteri Rahayu, Ph.D.)  
NIP. 19750115 199903 2 003

Surabaya, 2 Juli 2019



(Indana Lazulfa S)  
NRP. 06211745000010

\*(coret yang tidak perlu)

*Halaman ini sengaja dikosongkan*

## BIODATA PENULIS



Penulis bernama lengkap Indana Lazulfa Setyobudi, dilahirkan di Blitar pada tanggal 7 Januari 1996 sebagai seorang anak pertama dari dua bersaudara dari pasangan Budiono dan Lilik Setyowarni. Penulis bertempat tinggal di jalan

kelompok No. 5 RT. 19 RW. 04 Desa Kaumrejo Kec. Ngantang Kab. Malang. Penulis menyelesaikan pendidikan di TK. Adhi Prakarsa, SDN Kaumrejo 01 Ngantang tahun lulus 2008, SMPN 1 Ngantang lulus tahun 2011, SMAN 1 Batu lulus tahun 2014. Setelah lulus SMA penulis mengikuti seleksi penerimaan mahasiswa baru dan diterima di Departemen Statistika Bisnis prodi Diploma III dengan NRP 1314030025 dan masuk kuliah pada tahun 2014. Setelah lulus, penulis mengikuti seleksi penerimaan mahasiswa baru Lintas Jalur dan diterima di Departemen Statistika ITS dengan NRP 06211745000010 pada tahun 2017. Selama perkuliahan penulis memiliki pengalaman kerja sebagai Asisten Dosen mata kuliah Metode Multivariat Terapan dan Metode Riset Pemasaran. Selain itu, penulis juga aktif dalam organisasi yaitu sebagai anggota dan staff di UKM Kopma Dr. Angka ITS periode 2014/2015. Penulis juga aktif dalam berbagai kepanitiaan seperti Tim Soal Data Analysis Competition tahun 2016 dan PENTAKASI oleh HIMADATA-ITS. Penulis juga pernah mengikuti kegiatan pelatihan seperti LKMM-Pra TD, LKMM-TD, sosialisasi PKM 5 Bidang, Teknopreneurship, *Public Spaking*, PKTI, *Leadership Talk*, dan lain-lain. Pada akhir semester, penulis mendapat kesempatan kerja praktek di BPBD Provinsi Jawa Timur. Apabila pembaca memiliki kritik maupun saran atau ingin berdiskusi lebih lanjut dengan penulis maka hubungi penulis dengan kontak dibawah ini. 085655418926 atau lazulfaindana20@gmail.com.