



TESIS - SS14 2501

## **METODE ARIMAX, FFNN, DAN *HYBRID* ARIMAX- FFNN UNTUK PERAMALAN PERTAMAX**

UZZLIFATUS SYARIFAH  
NRP. 06211650010025

DOSEN PEMBIMBING :  
Dr.rer.pol. Heri Kuswanto, S.Si, M.Si.  
Dr. Suhartono, M.Sc.

PROGRAM MAGISTER  
JURUSAN STATISTIKA  
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2018



THESIS - SS14 2501

## **ARIMAX, FFNN, AND HYBRID ARIMAX-FFNN METHOD FOR FORECASTING PERTAMAX**

UZZLIFATUS SYARIFAH  
NRP. 06211650010025

SUPERVISOR :  
Dr.rer.pol. Heri Kuswanto, S.Si, M.Si.  
Dr. Suhartono, M. Sc.

PROGRAM OF MAGISTER  
DEPARTMENT OF STATISTICS  
FACULTY MATHEMATICS, COMPUTING, AND DATA SCIENCES  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2018

## LEMBAR PENGESAHAN

### METODE ARIMAX, FFNN, DAN *HYBRID* ARIMAX-FFNN UNTUK PERAMALAN PERTAMAX

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar  
Magister Sains (M.Si)  
di

Institut Teknologi Sepuluh Nopember  
Oleh:

**UZLIFATUS SYARIFAH**  
**NRP. 06211650010025**

Tanggal Ujian  
Periode Wisuda

: 22 Januari 2018  
: September 2018

Disetujui Oleh:

-   
1. Dr. rer.pol. Heri Kuswanto, M.Si. (Pembimbing I)  
NIP. 19820326 200312 1 004
-   
2. Dr. Suhartono, M.Sc. (Pembimbing II)  
NIP. 19710929 199512 1 001
-   
3. Dr. Bambang Widjanarko Otok, M.Si. (Penguji)  
NIP. 19681124 199412 1 001
-   
4. Dr. Santi Puteri Rahayu, S.Si., M.Si. (Penguji)  
NIP. 19750115 199903 2 003

Dekan

Fakultas Matematika, Komputasi, dan Sains Data  
Institut Teknologi Sepuluh Nopember



Prof. Dr. Basuki Widodo, M.Sc.  
NIP. 19650605 198903 1 002

## **Metode ARIMAX, FFNN, dan *Hybrid* ARIMAX-FFNN Untuk Peramalan Pertamina**

Nama mahasiswa : Uzlifatus Syarifah  
NRP : 06211650010025  
Pembimbing : 1. Dr. rer.pol. Heri Kuswanto, S. Si., M. Si.  
2. Dr. Suhartono, M.Sc.

### **ABSTRAK**

Peningkatan volume kendaraan bermotor berpengaruh terhadap tingkat kebutuhan bahan bakar. Banyaknya aktivitas yang dilakukan membuat kebutuhan bahan bakar semakin meningkat, terutama bagi masyarakat perkotaan sebagai contoh kota Surabaya yang memiliki tingkat mobilitas tinggi. Penelitian ini lebih difokuskan pada bahan bakar pertamax. Karena penjualan pertamax yang sangat dipengaruhi pertalite, maka salah satu metode yang bisa digunakan yaitu menggunakan metode peramalan ARIMAX dimana X adalah dummy sejak diluncurkan pertalite. Penelitian-penelitian sebelumnya metode ARIMAX telah memberikan hasil peramalan yang lebih baik, akan tetapi akurasi peramalan ARIMAX masih harus ditingkatkan. Salah satu cara untuk meningkatkan performa ARIMAX ini adalah dengan menggunakan model *hybrid*. Hasil analisis dan pembahasan yang dilakukan didapatkan Model ARIMAX (1,1,0) dengan menambahkan *outlier* didapatkan nilai RMSEP minimum. Pada FFNN menunjukkan bahwa nilai RMSEP yang minimum yaitu terdapat pada 2 *hidden layer* dengan masing-masing *neuron* tiap *hidden layer* 25 dan 30. Pada pemodelan *Hybrid* ARIMAX-FFNN menunjukkan bahwa 1 *hidden layer* dan jumlah *neuron* sebanyak 19 mempunyai nilai RMSEP minimum. Pemilihan model terbaik menunjukkan bahwa model terbaik adalah FFNN karena nilai RMSEP minimum.

**Kata kunci : Pertamina, FFNN, dan *Hybrid* ARIMAX-FFNN.**

*“Halaman ini sengaja dikosongkan”*

## **ARIMAX, FFNN, And Hybrid ARIMAX-FFNN Methods For Forecasting Pertamina**

Student Name : Uzlifatus Syarifah  
NRP : 06211650010025  
Supervisor : 1. Dr.rer.pol. Heri Kuswanto, S. Si., M. Si.  
2. Dr. Suhartono, M.Sc.

### **ABSTRACT**

Increased volume of motor vehicles affect the level of fuel needs. The number of activities carried out makes fuel needs increasing, especially for urban communities as an example of Surabaya city that has a high level of mobility. This research is more focused on Pertamina fuel. Because Pertamina sales are heavily influenced by Pertamina, then one of the methods that can be used is using ARIMAX forecasting method where X is dummy since launched Pertamina. Previous studies of ARIMAX methods have provided better forecasting results, but the accuracy of ARIMAX forecasting remains to be improved. One way to improve the performance of this ARIMAX is to use a hybrid model. Results of analysis and discussion conducted obtained ARIMAX Model (1,1,0) by adding outlier obtained minimum RMSEP value. In FFNN shows that the minimum RMSEP value is found in 2 hidden layers with each neuron of each hidden layer 25 and 30. In ARIMAX-FFNN Hybrid modeling shows that 1 hidden layer and number of neurons as much as 19 have minimum RMSEP value. The selection of the best model shows that the best model is FFNN because the RMSEP is minimum.

**Keyword : Pertamina, FFNN, and Hybrid ARIMAX-FFNN.**

*“Halaman ini sengaja dikosongkan”*

## KATA PENGANTAR

Puji syukur atas kehadiran Allah SWT atas segala rahmat, karunia, rizki, dan hidayah-Nya serta nikmat keimanan dan kesehatan merupakan salah satu nikmat berharga yang penulis rasakan selama proses pengerjaan Tesis ini, dengan kedua nikmat tersebut penulis akhirnya dapat menyelesaikan penulisan laporan Tesis dengan judul :

### **“Metode ARIMAX, FFNN, dan *Hybrid* ARIMAX-FFNN Untuk Peramalan Pertamina”**

Selama proses pengerjaan sampai tersusunnya laporan Tesis ini, penulis banyak dibantu oleh beberapa pihak. Untuk itu penulis ingin menyampaikan apresiasi dan ucapan terima kasih kepada :

1. Bapak Dr.rer.pol. Heri Kuswanto, S.Si.,M.Si. selaku Kepala Program Studi Pascasarjana Jurusan Statistika dan dosen pembimbing I serta Bapak Dr. Suhartono, M.Sc. selaku Ketua Jurusan Statistika dan dosen pembimbing II yang selama ini sudah banyak memberikan ilmunya dan bersabar dalam membimbing penulis selama proses pengerjaan Tesis.
2. Bapak Dr. Bambang Widjanarko Otok, M.Si. dan Ibu Dr. Santi Puteri Rahayu, M.Si. selaku dosen penguji penulis yang sudah memberikan kritik dan saran dalam Tesis.
3. Bapak Prof. Dr. Basuki Widodo, M.Sc.selaku Dekan Fakultas Matematika, Komputasi, dan Sains Data ITS.
4. Ibu Ismaini Zain, M.Si. selaku dosen wali penulis yang memberikan motivasi.
5. Dosen-dosen Jurusan Statistika ITS Surabaya yang telah memberikan ilmu dan semangat kepada penulis.
6. Kedua orang tua tercinta, Bapak Drs. H. M. Slamet Aliwasa, S.Pd. dan Ibu Hj. Nur Laily, S.Pd.,SD. yang sudah banyak memberikan dukungan dan doa untuk kelancaran dan kesuksesan penulis.
7. Mas Alif dan teman-teman PT. Pertamina (Persero) MOR V yang telah membantu penulis mulai dari kemudahan dalam memperoleh data, informasi



yang dibutuhkan serta dukungan maupun doa kepada penulis dalam pengerjaan Tesis.

8. Saudara-saudara tercinta Anita Nur Syahbana, S.M., Virly Rahmawati, S.E., dan Fahrizal Auliansyah yang telah memberikan doa dan motivasi kepada penulis.
9. Rizky Fichamdani, S.T. dan Kaysan Raskha Idyzraf yang telah memberikan doa, dorongan, dan dukungan serta motivasi dalam pengerjaan Tesis.
10. Teman-teman angkatan 2010 Silviah Rahmi, Jauhara Rana Budiani, dan Rizfanni Cahya Putri yang menempuh program magister Statistika ITS.
11. Teman-teman seperjuangan *time series* Mbak Reni, Mbak Nana, Atik, dan Meranggi yang telah memberikan doa, dukungan, motivasi, dan semangat dalam penyelesaian Tesis.
12. Teman-teman S2 angkatan 2016 yang telah memberikan doa, dukungan, motivasi, dan semangat dalam penyelesaian Tesis.
13. Pihak-pihak yang sudah banyak membantu penulis dalam proses pengerjaan Tesis ini, yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari bahwa laporan ini masih jauh dari kesempurnaan, untuk itu penulis menerima segala macam bentuk saran dan kritik yang diberikan untuk perbaikan laporan Tesis ini. Terakhir, penulis berharap semoga laporan ini dapat memberikan banyak manfaat untuk pembaca.

Surabaya, Februari 2018

**Penulis**

## DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL .....</b>	<b>i</b>
<b>LEMBAR PENGESAHAN .....</b>	<b>iii</b>
<b>ABSTRAK .....</b>	<b>v</b>
<b>ABSTRACT .....</b>	<b>vii</b>
<b>KATA PENGANTAR.....</b>	<b>ix</b>
<b>DAFTAR ISI.....</b>	<b>xi</b>
<b>DAFTAR TABEL .....</b>	<b>xiii</b>
<b>DAFTAR GAMBAR.....</b>	<b>xv</b>
<b>DAFTAR LAMPIRAN .....</b>	<b>xvii</b>
 <b>BAB I PENDAHULUAN</b>	
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah .....	5
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian.....	5
1.5 Batasan Masalah .....	6
 <b>BAB II TINJAUAN PUSTAKA</b>	
2.1 Tinjauan Statistik.....	7
2.1.1 <i>Autoregressive Integrated Moving Average with Exogenous                     Input (ARIMAX)</i> .....	7
2.1.2 <i>Neural Network (NN)</i> .....	18
2.1.3 <i>Pemodelan Hybrid ARIMAX-NN</i> .....	21
2.2 Tinjauan Non Statistik.....	23
2.2.1 <i>Pertamax</i> .....	23
2.2.1 <i>Pertalite</i> .....	24

### **BAB III METODOLOGI PENELITIAN**

3.1 Sumber Data.....	27
3.2 Variabel Penelitian.....	27
3.3 Struktur Data.....	27
3.4 Langkah-langkah Analisis.....	28

### **BAB IV ANALISIS DAN PEMBAHASAN**

4.1 Analisis Data Pengaruh Penjualan Pertalite Terhadap Pertamina Pada Wilayah Regional V Surabaya .....	35
4.2 Pemodelan Penjualan Pertamina dengan Metode ARIMAX .....	36
4.3 Pemodelan Penjualan Pertamina dengan Menggunakan Metode FFNN .....	45
4.4 Pemodelan Penjualan Pertamina dengan Metode <i>Hybrid</i> ARIMAX-FFNN .....	52
4.5 Perbandingan Pemilihan Model Terbaik Pada Data Penjualan Pertamina dengan Metode ARIMAX, FNN, dan <i>Hybrid</i> ARIMAX-FFNN.....	56

### **BAB V KESIMPULAN DAN SARAN**

5.1 Kesimpulan .....	61
5.2 Saran.....	61

<b>DAFTAR PUSTAKA .....</b>	<b>63</b>
-----------------------------	-----------

<b>LAMPIRAN .....</b>	<b>65</b>
-----------------------	-----------

<b>BIOGRAFI PENULIS.....</b>	<b>111</b>
------------------------------	------------

## DAFTAR TABEL

	Halaman
<b>Tabel 2. 1</b> Bentuk Transformasi Box-Cox.....	8
<b>Tabel 2. 2</b> Tabel <i>Dickey Fuller</i> .....	10
<b>Tabel 4. 1</b> Pengujian ANOVA Pengaruh Penjualan Peralite (kl) Terhadap Pertamax Serentak .....	36
<b>Tabel 4. 2</b> Pengujian ANOVA Pengaruh Penjualan Peralite (kl) Terhadap Pertamax Individu .....	36
<b>Tabel 4. 3</b> Hasil Pengujian ADF Penjualan Peralite (kl) Terhadap Pertamax .....	38
<b>Tabel 4. 4</b> Estimasi dan Pengujian Signifikansi Parameter Model ARIMAX Data Pertamax .....	40
<b>Tabel 4. 5</b> Uji Asumsi Residual <i>White Noise</i> Dugaan Model ARIMAX Data Penjualan Pertamax.....	40
<b>Tabel 4. 6</b> Uji Asumsi Residual <i>White Noise</i> Dugaan Model ARIMAX Data Penjualan Pertamax (Lanjutan).....	40
<b>Tabel 4. 7</b> Uji Asumsi Distribusi Normal Dugaan Model ARIMAX Data Penjualan Pertamax .....	41
<b>Tabel 4. 8</b> Kriteria Keباikan Dugaan Model ARIMAX Data Penjualan Pertamax .....	41
<b>Tabel 4. 9</b> Pendeteksian <i>Outlier</i> Pada Model ARIMAX .....	41
<b>Tabel 4. 10</b> Penjelasan Data Terjadinya <i>Outlier</i> .....	42
<b>Tabel 4. 11</b> Estimasi dan Pengujian Signifikansi Parameter Model ARIMAX Pada Data Penjualan Pertamax dengan Penambahan <i>Outlier</i> .....	42
<b>Tabel 4. 12</b> Uji Asumsi Residual <i>White Noise</i> Dugaan Model ARIMAX Data Penjualan Pertamax dengan Menambahkan <i>Outlier</i> .....	42
<b>Tabel 4. 13</b> Uji Asumsi Distribusi Normal Dugaan Model ARIMAX (1,1,0) Pada Data Penjualan Pertamax dengan Menambahkan <i>Outlier</i> .....	43

<b>Tabel 4. 14</b>	Nilai AIC, SBC, RMSE- <i>in</i> , dan RMSEP Model ARIMAX Data Penjualan Pertamax dengan Menambahkan <i>Outlier</i> .....	43
<b>Tabel 4. 15</b>	Hasil Uji Terasvirta .....	44
<b>Tabel 4. 16</b>	Kriteria Model Terbaik <i>Feedforward Neural Network</i> (FFNN) .....	45
<b>Tabel 4. 17</b>	Estimasi Parameter <i>Learning Feedforward Neural Network</i> (FFNN) <i>Layer Output</i> .....	46
<b>Tabel 4. 18</b>	Estimasi Parameter <i>Learning Feedforward Neural Network</i> (FFNN) <i>Layer</i> Tersembunyi Kedua .....	47
<b>Tabel 4. 19</b>	Estimasi Parameter <i>Learning Feedforward Neural Network</i> (FFNN) <i>Layer</i> Tersembunyi Kedua (Lanjutan 1) .....	48
<b>Tabel 4. 20</b>	Estimasi Parameter <i>Learning Feedforward Neural Network</i> (FFNN) <i>Layer</i> Tersembunyi Kedua (Lanjutan 2) .....	49
<b>Tabel 4. 21</b>	Estimasi Parameter <i>Learning Feedforward Neural Network</i> (FFNN) <i>Layer</i> Tersembunyi Kedua (Lanjutan 3) .....	50
<b>Tabel 4. 22</b>	Estimasi Parameter <i>Learning Feedforward Neural Network</i> (FFNN) Untuk <i>Layer</i> Tersembunyi Kesatu .....	51
<b>Tabel 4.23</b>	Kriteria Model Terbaik Metode <i>Hybrid</i> ARIMAX-FFNN.....	52
<b>Tabel 4.24</b>	Kriteria Model Terbaik Metode <i>Hybrid</i> ARIMAX-FFNN (Lanjutan).....	53
<b>Tabel 4.25</b>	Estimasi Parameter <i>Hybrid Learning Feedforward Neural</i> <i>Network</i> (FFNN) <i>Layer Output</i> .....	54
<b>Tabel 4.26</b>	Estimasi Parameter <i>Hybrid Learning Feedforward Neural</i> <i>Network</i> (FFNN) Untuk <i>Layer</i> Tersembunyi Kesatu.....	55
<b>Tabel 4.27</b>	Perbandingan Nilai RMSE Ketiga Metode .....	56
<b>Tabel 4.28</b>	Hasil Peramalan Penjualan Pertamax Agustus 2017-Juli 2018.....	57

## DAFTAR GAMBAR

	Halaman
<b>Gambar 2.1</b>	<i>Multilayer Perceptron</i> dengan Dua Hidden Layer .....19
<b>Gambar 3.1</b>	<i>Flow Chart</i> Langkah-langkah Analisis Metode ARIMAX.....30
<b>Gambar 3.2</b>	<i>Flow Chart</i> Langkah-langkah Analisis Metode <i>Feedforward Neural Network</i> (FFNN) .....31
<b>Gambar 3.3</b>	<i>Flow Chart</i> Langkah-langkah Analisis Metode <i>Hybrid</i> ARIMAX-FFNN .....31
<b>Gambar 3.4</b>	Ilustrasi Pembentukan Model Metode <i>Hybrid</i> ARIMAX- FFNN Tahap 1 .....32
<b>Gambar 3.5</b>	Ilustrasi Pembentukan Model Metode <i>Hybrid</i> ARIMAX- FFNN Tahap 2 .....33
<b>Gambar 4.1</b>	Plot Penjualan Peralite Terhadap Pertamina Pada Januari 2010-Juli 2017 .....35
<b>Gambar 4.2</b>	Plot Penjualan Produk Pertamina Januari 2010-Juli 2016 .....37
<b>Gambar 4.3</b>	Plot ACF (a) dan PACF (b) Penjualan Produk Pertamina Pada Januari 2010-Juli 2016 .....37
<b>Gambar 4.4</b>	Plot Box-Cox Penjualan Produk Pertamina Pada Januari 2010-Juli 2016 .....38
<b>Gambar 4.5</b>	Plot <i>Differencing</i> Penjualan Produk Pertamina Pada Januari 2010-Juli 2016 .....39
<b>Gambar 4.6</b>	Plot ACF (a) dan PACF (b) Setelah Dilakukan <i>Differencing</i> Penjualan Produk Pertamina Pada Januari 2010-Juli 2016.....39
<b>Gambar 4.7</b>	Plot Box-Cox Setelah Dilakukan <i>Differencing</i> Penjualan Produk Pertamina Pada Januari 2010-Juli 2016.....40
<b>Gambar 4.8</b>	Pola Data Non-Linear .....44
<b>Gambar 4.9</b>	Arsitektur FFNN (1-25-30-1) .....46
<b>Gambar 4.10</b>	Arsitektur <i>Hybrid</i> ARIMAX-FFNN (1-19-1) .....53

<b>Gambar 4.11</b>	Perbandingan Nilai RMSE Ketiga Metode .....	57
<b>Gambar 4.12</b>	Plot Data Penjualan Produk Pertamina Periode Januari 2010-Juli 2018 .....	58
<b>Gambar 4.13</b>	Plot <i>Fits-In</i> (a) dan <i>Fits-Out</i> (b) Data Penjualan Produk Pertamax .....	59

## DAFTAR LAMPIRAN

	Halaman
<b>Lampiran 1</b> Data Penjualan Pertamina dan Pertamina di Regional V Surabaya ....	65
<b>Lampiran 2</b> Analisis ANOVA Pengaruh Penjualan Pertamina (kl) Terhadap Pertamax Secara Serentak dan Individu .....	68
<b>Lampiran 3</b> Hasil Proses Pemodelan ARIMAX .....	69
<b>Lampiran 4</b> Hasil Proses Pemodelan <i>Feedforward Neural Network</i> .....	89
<b>Lampiran 5</b> Hasil Proses Pemodelan <i>Hybrid ARIMAX-Feedforward Neural Network</i> .....	103
<b>Lampiran 6</b> Pemilihan Model Terbaik .....	108
<b>Lampiran 7</b> Hasil Peramalan Penjualan Pertamina 12 Periode ke Depan .....	109
<b>Lampiran 8</b> <i>Fits</i> Data Penjualan Pertamina <i>In-Sample</i> dan <i>Out-Sample</i> .....	109



*“Halaman ini sengaja dikosongkan”*

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Peningkatan volume kendaraan bermotor berpengaruh terhadap tingkat kebutuhan bahan bakar. Kendaraan bermotor yang awalnya merupakan kebutuhan tersier bergeser menjadi kebutuhan sekunder, bahkan mungkin kebanyakan orang menganggap sebagai kebutuhan pokok. Seiring dengan pergeseran tingkat kebutuhan tersebut, bahan bakar minyak sebagai materi utama untuk menjalankan mesin kendaraan bermotor pun turut menjadi kebutuhan utama yang selalu dicari masyarakat, khususnya wilayah Surabaya yang mendominasi kendaraan roda dua maupun roda empat. Banyaknya aktivitas yang dilakukan membuat kebutuhan bahan bakar semakin meningkat, terutama bagi masyarakat perkotaan sebagai contoh kota Surabaya yang memiliki tingkat mobilitas tinggi.

Tingginya tingkat kendaraan bermotor dan untuk mencegah kelangkaan pasokan bahan bakar setiap bulannya, PT. Pertamina (Persero) Regional V Surabaya dimana tugas utamanya menerima, menyimpan, dan menyalurkan bahan bakar sesuai spesifikasi atau standar mutu yang telah ditetapkan harus bisa memenuhi kebutuhan konsumen adanya permintaan bahan bakar. Ini merupakan tantangan bagi PT. Pertamina (Persero) Regional V Surabaya agar dapat meningkatkan pelayanannya, dimana PT. Pertamina (Persero) Regional V Surabaya merupakan perusahaan minyak dan gas bumi yang dimiliki Pemerintah untuk mengoptimalkan kebutuhan konsumen akan bahan bakar agar dapat terpenuhi. Oleh karena itu, diperlukan informasi dan ramalan kebutuhan bahan bakar secara akurat dalam memenuhi persediaan untuk pengambilan keputusan kebijakan yang dilakukan perusahaan sehingga dapat meningkatkan efisiensi.

Produk bahan bakar jenis pertamax yaitu produk bahan bakar yang dihasilkan PT. Pertamina (Persero) Regional V Surabaya dengan jumlah permintaan kebutuhan yang cukup tinggi, untuk itu penelitian ini lebih difokuskan pada bahan bakar pertamax. Karena penjualan pertamax yang sangat dipengaruhi pertalite, maka salah satu metode yang bisa digunakan yaitu menggunakan metode

peramalan *Autogressive Integrated Moving Average with Exogeneous* (ARIMAX) dimana X adalah variabel *exogenous*. Variabel *exogenous* merupakan variabel yang dapat mempengaruhi variabel endogen/ respon. Terkait dalam penelitian ini variabel *exogenous* yang digunakan yaitu variabel dummy sejak diluncurkan pertalite dan volume penjualan pertalite. Harapan PT. Pertamina (Persero) Regional V Surabaya dengan diluncurkan produk baru Juli 2015 yaitu pertalite tidak akan mempengaruhi penjualan produk pertamax karena untuk kelangsungan mesin kendaraan dengan menggunakan pertamax membuat mesin lebih awet. Tujuan dari dikeluarkan produk baru pertalite bukan untuk menurunkan penjualan pertamax, melainkan hanya menggantikan premium yang akan mulai dihentikan secara perlahan-lahan.

Model *Autogressive Integrated Moving Average with Exogenous* (ARIMAX) merupakan perluasan dari model ARIMA yang dapat menangani analisis intervensi maupun kasus *outlier* (Cryer & Chan, 2008). Pembentukan model *Autogressive Integrated Moving Average with Exogenous* (ARIMAX) meliputi model dengan data metrik sebagai input yang disebut model fungsi transfer, model dengan data non-metrik sebagai input disebut model intervensi, dan efek terjadinya Hari Raya Idul Fitri disebut dengan model variasi kalender. Model *Autogressive Integrated Moving Average with Exogenous* (ARIMAX) juga merupakan model ARIMA dengan tambahan variabel prediktor (Cryer dan Chan, 2008). Model *Autogressive Integrated Moving Average with Exogenous* (ARIMAX) pada penelitian ini dilakukan dengan menambahkan variabel dummy. Variabel dummy adalah variabel yang digunakan untuk mengkuantitatifkan variabel yang bersifat kualitatif (misal: jenis kelamin, ras, agama, perubahan kebijakan pemerintah, perbedaan situasi, dan lain-lain). Variabel dummy merupakan variabel yang bersifat kategorikal yang diduga mempunyai pengaruh terhadap variabel yang bersifat kontinu. Variabel dummy sering juga disebut variabel boneka, *binary*, atau kategorik. Variabel dummy hanya mempunyai 2 (dua) nilai yaitu 1 dan nilai 0, serta diberi simbol D (Gujarati, 2004).

Penelitian-penelitian sebelumnya metode *Autogressive Integrated Moving Average with Exogenous* (ARIMAX) telah memberikan hasil peramalan yang

lebih baik, akan tetapi akurasi peramalan *Autogressive Integrated Moving Average with Exogenous* (ARIMAX) masih harus ditingkatkan. Salah satu cara untuk meningkatkan performa ARIMAX ini adalah dengan menggunakan model *hybrid*. Model ini mengkombinasikan keuntungan dari model linear dan non-linear. Seperti yang kita tahu, model linear seperti *Autogressive Integrated Moving Average with Exogenous* (ARIMAX) memiliki keuntungan dengan mudahnya diinterpretasikan. Di sisi lain, non-linear model diketahui memiliki tingkat akurasi yang tinggi, biasanya untuk data *training*, akan tetapi sulit untuk diinterpretasikan. Model *Hybrid* dikenalkan oleh Zhang (2003) dimana ia mengkombinasikan ARIMA sebagai komponen linear dan *Neural Network* (NN) sebagai komponen non-linearnya. Hasil penelitian dari Zhang menunjukkan bahwa *Hybrid* ARIMA-NN dapat meningkatkan tingkat akurasi peramalan dibandingkan dengan hasil dari peramalan ARIMA atau NN secara terpisah. Mempertimbangkan keuntungan *Hybrid* seperti dijelaskan di atas, maka penelitian ini akan menggunakan metode *Hybrid* ARIMAX-FFNN untuk melihat apakah tingkat akurasi dari penjualan pertamax dapat menjadi lebih baik ketika menggunakan metode ini. Bukan tidak mungkin struktur data *time series* tertentu terbentuk dari struktur linear dan non-linear sekaligus (Zhang, 2003). Pada data seperti ini, model ARIMAX hanya dapat menangkap hubungan linear, sehingga komponen non-linear masih ada pada error. Berdasarkan prosedur model *hybrid*, *residual* butuh untuk dimodelkan dengan model non-linear.

*Neural Network* (NN) merupakan model yang dapat membentuk berbagai jenis data non-linear. Keuntungan menggunakan NN adalah tidak ada spesifikasi atau asumsi khusus yang harus digunakan sebelum membentuk model (Zhang & Berardi, 1998). NN telah banyak digunakan pada peramalan data *time series*, seperti pada penelitian Faraway dan Chatfield (1998) serta Prayoga *et al* (2015). Terdapat beberapa komponen yang harus dipertimbangkan dalam metode NN *modeling*, yaitu *neuron*, *layer*, fungsi aktivasi, dan bobot. Komponen-komponen ini akan sangat mempengaruhi dalam menentukan model NN karena pembentukan model NN didasarkan pada jumlah *neuron* dalam *input layer*, *hidden layer*, dan *output layer* serta fungsi aktivasi (Kusumadewi, 2004). Penentuan *hidden layer*

menurut menurut Chester (1990) dua lapisan tersembunyi (*two hidden layer*) NN telah terbukti mengungguli *one hidden layer* untuk aproksimasi fungsi pada banyak kasus.

Beberapa penelitian sebelumnya pernah dilakukan terkait pemodelan *Hybrid* yaitu Kusumaningrum (2012) mengenai peramalan kebutuhan bahan bakar premium di Depot Ampenan dengan metode Hibrida ARIMA-*Neural Network* untuk optimasi persediaan didapatkan hasil perbandingan model ARIMA, NN, dan Hibrida ARIMA-NN menunjukkan bahwa model Hibrida ARIMA-NN menghasilkan nilai RMSE dan MAPE terkecil dibandingkan dengan model tunggal yaitu ARIMA dan NN. Wulansari (2014) melakukan penelitian mengenai peramalan *outflow* tiap pecahan uang kartal dengan metode ARIMAX, *Hybrid* ARIMAX-ANN, dan VARI-X didapatkan hasil peramalan terbaik untuk tiap pecahan mata uang berbeda-beda. Susanto (2016) melakukan penelitian mengenai pemodelan curah hujan dengan pendekatan model ARIMA, *Feedforward Neural Network* dan *Hybrid* ARIMA-NN di Banyuwangi didapatkan hasil dari ketiga metode pemodelan dengan *Feedforward Neural Network* (FFNN) menghasilkan nilai RMSE *out sampel* yang paling kecil. Perbedaan penelitian ini dengan penelitian sebelumnya dari sisi variabel yaitu variabel pertamax dan metode yang digunakan *Hybrid* ARIMAX-FFNN untuk NN menggunakan *Feedforward Neural Network* (FFNN).

Penelitian tentang pengaruh penjualan pertalite terhadap pertamax diharapkan dapat memberikan masukan atau saran mengenai peramalan kebutuhan yang dapat digunakan sebagai informasi yang diberikan melalui analisis peramalan agar PT. Pertamina (Persero) Regional V Surabaya dapat meningkatkan efisiensi produk bahan bakar pertamax karena bahan bakar pertamax dapat membuat oli, tune up, ruang bakar, dan kuras radiator lebih bersih serta tarikan lebih enteng dibandingkan bahan bakar pertalite. Jika sudah terlalu kotor, biaya servis kendaraan akan lebih mahal. Meskipun harga bahan bakar pertamax lebih mahal jika dibandingkan dengan harga bahan bakar pertalite, tetapi manfaatnya sangat besar untuk kelangsungan mesin kendaraan.

## **1.2 Rumusan Masalah**

Berdasarkan pada latar belakang yang telah diuraikan, adapun rumusan masalah yang akan dibahas adalah bagaimana menentukan dan mendapatkan model yang sesuai untuk meramalkan volume penjualan pertamax Agustus 2017-Juli 2018 dengan adanya pengaruh penjualan pertalite menggunakan metode ARIMAX, FFNN, dan *Hybrid* ARIMAX-FFNN.

## **1.3 Tujuan Penelitian**

Berdasarkan rumusan masalah, maka ada lima tujuan penelitian yang akan dicapai sebagai berikut :

1. Mendapatkan model data penjualan pertamax di PT. Pertamina (Persero) Region V Surabaya pada Januari 2010 – Juli 2017 menggunakan metode ARIMAX.
2. Mendapatkan model data penjualan pertamax di PT. Pertamina (Persero) Region V Surabaya pada Januari 2010 – Juli 2017 menggunakan metode FFNN.
3. Mendapatkan model data penjualan pertamax di PT. Pertamina (Persero) Region V Surabaya pada Januari 2010 – Juli 2017 menggunakan metode *Hybrid* ARIMAX-FFNN.
4. Mendapatkan model yang sesuai untuk meramalkan data penjualan pertamax di PT. Pertamina (Persero) Region V Surabaya pada Agustus 2017-Juli 2018.

## **1.4 Manfaat Penelitian**

Hasil dari penelitian ini diharapkan mampu memberikan manfaat bagi beberapa pihak, yaitu :

1. Bagi perusahaan : memberikan informasi dan masukan atau saran dalam mengambil kebijakan pendistribusian perusahaan PT. Pertamina (Persero) Region V Surabaya serta dapat memenuhi kebutuhan konsumen dengan baik.

2. Bagi peneliti : menerapkan ilmu statistik dalam kasus riil sebagai contoh dalam penelitian ini untuk mendapatkan model yang sesuai dalam peramalan kebutuhan pertamax pada Agustus 2017-Juli 2018.

### **1.5 Batasan Masalah**

Penelitian ini dibatasi pada data penjualan pertamax. Data ini berupa data bulanan penjualan pertamax Region V Surabaya periode Januari 2010 hingga Juli 2017. Variabel *exogenous* yaitu produk pertalite. *Neural Network* (NN) yang digunakan adalah *Feedforward* atau *Multilayer Perceptron* dengan fungsi aktivasi pada *hidden layer* adalah fungsi sigmoid. *Learning* yang digunakan adalah algoritma *back-propagation* dibatasi dengan menggunakan 1 hingga 2 pada *hidden layer*.

## BAB II

### TINJAUAN PUSTAKA

Pada tinjauan pustaka akan dibagi menjadi dua bagian, yaitu bagian tinjauan statistika yang menjelaskan metode yang akan digunakan untuk menunjang penelitian dan bagian tinjauan non statistik yang menjelaskan studi kasus yang akan diteliti.

#### 2.1 Tinjauan Statistik

Tinjauan statistik yang digunakan pada penelitian ini yaitu model ARIMA *with Exogenous Input* (ARIMAX), *Neural Network* (NN), dan *Hybrid* ARIMAX-FFNN.

##### 2.1.1 *Autoregressive Integrated Moving Average with Exogenous Input* (ARIMAX)

Model ARIMAX adalah model ARIMA dengan tambahan variabel. Terdapat beberapa jenis tambahan variabel, misalnya variabel *dummy* untuk periode sejak produk pertalite diluncurkan dan volume penjualan produk pertalite. Model ARIMAX adalah sebagai berikut (Cryer & Chan, 2008):

$$\dot{Z}_t = \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_k V_{k,t} + \frac{\theta_q(B) \Theta_Q(B^S)}{\phi_p(B) \Phi_P(B^S) (1-B)^d (1-B^S)^D} a_t, \quad (2.1)$$

dengan:

$V_{k,t}$  : variabel *dummy* untuk periode sejak produk pertalite diluncurkan ke- $k$ ,

$\beta$  : koefisien parameter variabel *dummy*.

##### a. Identifikasi Model ARIMAX

Terdapat beberapa tahap dalam melakukan identifikasi model. Langkah pertama dari identifikasi model adalah mengidentifikasi kestasioneran data. Kemudian jika data telah stasioner, dilakukan identifikasi order ARIMAX berdasarkan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).

Suatu data harus stasioner baik dalam *mean* maupun *varians*. Kestasioneran dalam *mean* dapat dilihat pada *time series* plot. Sedangkan kestasioneran dalam



*varians* dapat dilihat pada plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Apabila data belum stasioner dalam *varians*, maka dilakukan transformasi data. Metode transformasi yang terkenal adalah transformasi Box-Cox yang ditampilkan pada Tabel 2.1 (Wei, 2006).

**Tabel 2. 1** Bentuk Transformasi Box-Cox

Nilai $\lambda$	Transformasi yang Sesuai
-1,0	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0	$\ln(Z_t)$
0,5	$\sqrt{Z_t}$
1	$Z_t$

Apabila data belum stasioner dalam *mean*, maka dilakukan *differencing*. Formula dari ACF untuk identifikasi order ARIMAX adalah sebagai berikut (Wei, 2006).

$$\rho_k = \frac{\text{Cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)}\sqrt{\text{Var}(Z_{t+k})}}, \quad (2.2)$$

dimana:

$\rho_k$  : autokorelasi pada lag ke -  $k$ ,

$k$  : 1,2,3,...

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

$$\text{Var}(Z_t) = \text{Var}(Z_{t+k}).$$

Sedangkan ACF yang digunakan dalam sampel adalah sebagai berikut (Wei, 2006):

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}. \quad (2.3)$$

PACF adalah korelasi antara  $Z_t$  dan  $Z_{t-k}$  setelah pengaruh  $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$  dihilangkan. Formula dari PACF adalah sebagai berikut:

$$\varepsilon_k = \frac{\text{Cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)} \sqrt{\text{Var}(Z_{t+k} - \hat{Z}_{t+k})}}. \quad (2.4)$$

Sedangkan PACF yang digunakan dalam sampel adalah sebagai berikut (Wei, 2006) :

$$\hat{\varepsilon}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\varepsilon}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\varepsilon}_{kj} \hat{\rho}_j}, \quad (2.5)$$

dan

$$\hat{\varepsilon}_{k+1,j} = \hat{\varepsilon}_{kj} - \hat{\varepsilon}_{k+1,k+1} \hat{\varepsilon}_{k,k+1-j}, \quad j=1,2,\dots,k. \quad (2.6)$$

Apabila data belum stasioner dalam rata-rata, maka dilakukan *differencing*. Pengujian ketidakstasioneran dalam rata-rata menggunakan uji *Augmented Dickey-Fuller* (ADF).

Uji ADF dibagi menjadi uji ADF *non-seasonal* dan uji ADF *seasonal*. Persamaan regresi untuk uji ADF *seasonal* adalah (Enders, 2004):

1. Model *Random Walk*

$$\Delta Z_t = \delta Z_{t-1} + \sum_{i=1}^p \gamma_i \Delta Z_{t-i} + a_t \quad (2.8)$$

2. Model dengan *intercept* atau *trend*

$$\Delta Z_t = \eta_0 + \delta Z_{t-1} + \sum_{i=1}^p \gamma_i \Delta Z_{t-i} + a_t \quad (2.9)$$

3. Model dengan *intercept* dan *trend*

$$\Delta Z_t = \eta_0 + \eta_1 tr + \delta Z_{t-1} + \sum_{i=1}^p \gamma_i \Delta Z_{t-i} + a_t \quad (2.10)$$

Sedangkan uji ADF *seasonal* menggunakan model multiplikatif sebagai berikut (Dickey, Hasza, & Fuller, 1984).

$$(1 - \alpha_d B^d)(1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_p B^p)Z_t = a_t \quad (2.11)$$

Uji ADF merupakan pengembangan dari uji *Dickey-Fuller* (DF). Uji DF merupakan uji *unit root* yang menggunakan uji statistik tau ( $\tau$ ) dengan hipotesis:

$$H_0 : \delta = 0,$$

$$H_1 : \delta \neq 0.$$

Statistik uji yang digunakan dalam pengujian ini adalah:

$$\tau = \frac{\hat{\delta}}{SE(\hat{\delta})}. \quad (2.7)$$

Tolak  $H_0$  apabila nilai  $|\tau| > \tau_{\text{tabel}}$  atau  $p\text{-value} < \alpha$  yang menunjukkan bahwa data sudah stasioner dalam rata-rata. Ada tiga jenis pembandingan  $\tau$ , antara lain apabila persamaan uji ADF tanpa *intercept* atau *trend* menggunakan statistik  $\tau_{nc}^*$ , apabila persamaan melibatkan *intercept* menggunakan statistik  $\tau_c^*$ , dan apabila persamaan melibatkan *intercept* dan *trend* menggunakan statistik  $\tau_{tc}^*$ . Nilai-nilai pembandingan tersebut ditampilkan pada Tabel 2.2 (Gujarati, 2004).

**Tabel 2. 2** Tabel *Dickey-Fuller*

Ukuran Sampel	$\tau_{nc}^*$		$\tau_c^*$		$\tau_{tc}^*$	
	1%	5%	1%	5%	1%	5%
25	-2.66	-1.95	-3.75	-3.00	-4.38	-3.60
50	-2.62	-1.95	-3.58	-2.93	-4.15	-3.50
100	-2.60	-1.95	-3.51	-2.89	-4.04	-3.45
250	-2.58	-1.95	-3.46	-2.88	-3.99	-3.43
500	-2.58	-1.95	-3.44	-2.87	-3.98	-3.42
	-2.58	-1.95	-3.43	-2.86	-3.96	-3.41

Uji DF dilakukan dengan asumsi bahwa  $\alpha_t$  tidak berkorelasi. Ketika  $\alpha_t$  berkorelasi, uji DF dikembangkan menjadi uji ADF (Gujarati, 2004).

Statistik uji ADF seasonal diperoleh dengan langkah:

1. Estimator awal  $\hat{\theta}_i$  dan taksiran residual  $\hat{a}_i$  diperoleh dengan melakukan regresi  $\Delta^d Z_t$  dengan  $\Delta^d Z_{t-1}, \dots, \Delta^d Z_{t-p}$ .
2. Melakukan regresi  $\hat{a}_i$  dengan  $(1 - \hat{\theta}_1 B - \hat{\theta}_2 B^2 - \dots - \hat{\theta}_p B^p) Z_{t-d}$ ,  $\Delta^d Z_{t-1}$ , ...,  $\Delta^d Z_{t-p}$  untuk mendapatkan estimasi  $\delta$  dan  $\theta_i - \hat{\theta}_i$ .

**b. Estimasi ARIMAX dengan Conditional Least Square (CLS)**

**i. Estimasi Conditional Least Square untuk Model Autoregressive**

Untuk model AR(1) dimana :

$$\begin{aligned} Z_t - \mu_0 &= \phi(Z_{t-1} - \mu_0) + a_t \\ a_t &= (Z_t - \mu_0) - \phi(Z_{t-1} - \mu_0). \end{aligned} \quad (2.12)$$

dengan  $n$  observasi, residual yang dapat dijumlahkan hanya dari  $t = 2$  hingga  $t = n$ . Fungsi dari *conditional sum of square* adalah sebagai berikut (Cryer & Chan, 2008):

$$S_c(\phi, \mu_0) = \sum_{t=2}^n [(Z_t - \mu_0) - \phi(Z_{t-1} - \mu_0)]^2, \quad (2.13)$$

$\mu_0$  dan  $\phi$  diestimasi dari nilai masing-masing yang meminimumkan  $S_c(\phi, \mu_0)$  dari nilai observasi  $Z_1, Z_2, \dots, Z_n$ . Hasil meminimumkan dari penyelesaian  $\mu_0$  adalah:

$$\frac{\partial S_c(\phi, \mu_0)}{\partial \mu_0} = \sum_{t=2}^n 2[(Z_t - \mu_0) - \phi(Z_{t-1} - \mu_0)](-1 + \phi) = 0. \quad (2.14)$$

Solusi untuk  $\mu_0$  adalah:

$$\mu_0 = \frac{1}{(n-1)(1-\phi)} \left[ \sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1} \right]. \quad (2.15)$$

Untuk  $n$  besar,

$$\frac{1}{n-1} \sum_{t=2}^n Z_t \approx \frac{1}{n-1} \sum_{t=2}^n Z_{t-1} \approx \bar{Z}.$$

Sehingga, tanpa memperhatikan nilai  $\phi$ , persamaan (2.16) tereduksi menjadi:

$$\hat{\mu}_0 = \frac{1}{1-\phi} [\bar{Z} - \phi \bar{Z}] = \bar{Z}. \quad (2.16)$$

Perhitungan ini juga dapat digunakan dalam proses estimasi AR( $p$ ) lainnya secara umum (Cryer & Chan, 2008). Sedangkan hasil meminimumkan dari penyelesaian  $\phi$  adalah:

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

Sehingga solusi  $\phi$  untuk adalah:

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

Untuk menggeneralisasi estimasi dari  $\phi$ , model AR(2) dipertimbangkan. Dalam fungsi *conditional sum of square*, diganti menjadi, sehingga:

$$S_c(\phi_1, \phi_2, \bar{Z}) = \sum_{t=3}^n [(Z_t - \bar{Z}) - \phi_1(Z_{t-1} - \bar{Z}) - \phi_2(Z_{t-2} - \bar{Z})]^2. \quad (2.19)$$

Maka hasil meminimumannya adalah:

$$\frac{\partial S_c}{\partial \phi_1} = -2 \sum_{t=3}^n [(Z_t - \bar{Z}) - \phi_1(Z_{t-1} - \bar{Z}) - \phi_2(Z_{t-2} - \bar{Z})](Z_{t-1} - \bar{Z}) = 0. \quad (2.20)$$

Dapat dituliskan sebagai berikut:

$$\begin{aligned} \sum_{t=3}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z}) &= \left( \sum_{t=3}^n (Z_{t-1} - \bar{Z})^2 \right) \phi_1 \\ &+ \left( \sum_{t=3}^n (Z_{t-1} - \bar{Z})(Z_{t-2} - \bar{Z}) \right) \phi_2. \end{aligned} \quad (2.21)$$

Jika kedua sisi dari persamaan (2.16) dibagi dengan  $\sum_{t=3}^n (Z_t - \bar{Z})^2$ , maka kecuali efek terakhir, yang diabaikan asumsi stasioneritasnya:

$$\rho_1 = \phi_1 + \rho_1 \phi_2 \cdot \quad (2.22)$$

Dengan cara yang sama, untuk perhitungan  $\partial S_c / \partial \phi_2 = 0$  menghasilkan:

$$\rho_2 = \rho_1 \phi_1 + \phi_2 \cdot \quad (2.23)$$

Persamaan (2.17) dan (2.18) adalah contoh persamaan Yule-Walker untuk model AR(2). Untuk model stasioner AR( $p$ ) secara umum, estimasi *conditional least square* dari  $\phi$  didapatkan dari penyelesaian persamaan Yule-Walker (Cryer & Chan, 2008).

## ii. Estimasi *Conditional Least Square* untuk Model *Moving Average*

Untuk model MA(1) dimana:

$$Z_t = a_t - \theta a_{t-1} \quad (2.24)$$

Model MA(1) dapat dituliskan menjadi sebuah model *autoregressive* dengan *infinite order* sebagai berikut:

$$Z_t = -\theta Z_{t-1} - \theta^2 Z_{t-2} - \theta^3 Z_{t-3} - \dots + a_t \quad (2.25)$$

Sehingga, *conditional least square* dapat diaplikasikan lewat pemilihan nilai  $\theta$  yang meminimumkan:

$$S_c(\theta) = \sum_t a_t^2 = \sum_t [Z_t + \theta Z_{t-1} + \theta^2 Z_{t-2} + \theta^3 Z_{t-3} + \dots]^2 \quad (2.26)$$

dimana  $a_t = a_t(\theta)$  adalah fungsi series dan parameter  $\theta$  yang tidak diketahui. Untuk model MA( $q$ ) secara umum, dibutuhkan algoritma optimasi numerik (Cryer & Chan, 2008).

## iii. Estimasi *Conditional Least Square* untuk ARIMAX (Model *Mixed*)

Untuk model ARMA(1,1):

$$\begin{aligned} Z_t &= \phi Z_{t-1} + a_t - \theta a_{t-1} \\ a_t &= Z_t - \phi Z_{t-1} + \theta a_{t-1} \end{aligned} \quad (2.27)$$

Parameternya diestimasi lewat meminimumkan:

$$S_c(\phi, \theta) = \sum_{t=2}^n a_t^2 \quad (2.28)$$

Untuk model umum ARMA( $p, q$ ):

$$a_t = Z_t - \phi_1 Z_{t-1} - \phi_2 Z_{t-2} - \dots - \phi_p Z_{t-p} + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (2.29)$$

dengan  $a_p = a_{p-1} = \dots = a_{p+1-q} = 0$ . Semua parameter dapat diperoleh dengan meminimumkan secara numerik (Cryer & Chan, 2008).

Tahap selanjutnya adalah melakukan uji kelayakan model ARIMA. Jika uji terhadap parameter adalah signifikan, maka model dianggap layak. Hipotesis yang digunakan dalam uji signifikansi parameter misal untuk AR (1) adalah sebagai berikut:

$$H_0 : \phi_1 = 0$$

$$H_1 : \phi_1 \neq 0$$

dengan  $\phi_1$  adalah estimasi parameter model. Statistik uji yang digunakan uji t dituliskan pada persamaan (2.24) sebagai berikut:

$$t_{hitung} = \frac{\hat{\phi}_1}{SE(\hat{\phi}_1)} \quad (2.30)$$

Daerah penolakan  $H_0$  adalah  $|t_{hitung}| > t_{\alpha/2, n-n_p}$ , dimana:  $n$  adalah banyaknya observasi, sedangkan  $n_p$  adalah banyaknya parameter dalam model.

### c. Asumsi pada Model ARIMAX

Model ARIMAX yang baik adalah yang residualnya memenuhi asumsi *white noise* dan berdistribusi normal. Arti *white noise* sendiri adalah residual pada waktu  $t$  tidak memiliki korelasi dengan *residual* pada waktu  $t - k$  dimana  $k = 1, 2, 3, \dots$ . Kondisi *white noise* dapat diuji dengan pengujian Ljung-Box dengan hipotesis:

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

$$H_1 : \text{paling tidak ada satu } \rho_k \neq 0 \text{ dimana } k = 1, 2, \dots, K.$$

Dengan statistik uji:

$$Q_K = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)} \quad (2.31)$$

$H_0$  ditolak jika  $Q_K$  lebih besar nilainya dari  $\chi_{\alpha; K-p-q}^2$  atau  $p\text{-value} < \alpha$  (Tsay, 2005).

Kenormalan dari residual dapat diperiksa dengan menggunakan uji Kolmogorov Smirnov dengan hipotesis:

$$H_0 : F_n(a_t) = F_0(a_t)$$

$$H_1 : F_n(a_t) \neq F_0(a_t).$$

Statistik ujinya adalah:

$$D = \sup_{a_t} |F_n(a_t) - F_0(a_t)| \quad (2.32)$$

dimana  $F_n(a_t)$  adalah distribusi kumulatif dari *residual* dan  $F_0(a_t)$  adalah distribusi kumulatif dari distribusi normal.  $H_0$  ditolak jika  $D$  lebih besar dari  $D_{(1-\alpha, n)}$  atau  $p\text{-value} < \alpha$  (Daniel, 1989).

#### d. Deteksi *Outlier*

*Outlier* dalam suatu data deret waktu merupakan suatu data pengamatan yang tidak konsisten sebagai akibat dari adanya kejadian luar biasa yang tidak terduga dan tanpa disadari seperti pemogokan, wabah perang, krisis politik atau ekonomi yang berkejolak. Pengamatan tersebut biasa dikenal dalam *time series* berupa *outlier*. Deteksi *outlier* pertama kali diperkenalkan oleh Fox (1972) dalam (Wei, 2006). *Outlier* terdiri dari beberapa tipe, yaitu *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS) dan *Temporary Change* (TC). Cara mengatasi *outlier* dengan memasukkan *outlier* dalam model sampai mendapatkan model yang memenuhi asumsi *white noise* dan berdistribusi normal.



**i. Additive Outlier (AO)**

*Additive Outlier* (AO) merupakan kejadian yang mempengaruhi suatu deret runtun waktu pada satu waktu saja.  $X_t$  diasumsikan mengikuti pola ARMA( $p, q$ ) Wei (2006) mendefinisikan model *additive outlier* sebagai berikut :

$$Y_t = \begin{cases} X_t + \omega, t = T \\ X_t, t \neq T \end{cases} \quad (2.33)$$

atau,

$$\begin{aligned} Y_t &= X_t + \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\varphi(B)} a_t + \omega I_t^{(T)} \end{aligned} \quad (2.34)$$

dengan,

$$I_t^{(T)} = \begin{cases} 1, t = T \\ 0, t \neq T \end{cases} \quad (2.35)$$

$X_t$  adalah model ARIMA sebelum deteksi *outlier*

$I_t^{(T)}$  adalah variabel *outlier* pada waktu ke- $T$ .

**ii. Innovational Outlier (IO)**

Data *time series* yang mengandung *Innovational Outlier* (IO) memberikan efek yang lebih rumit jika dibandingkan ketiga tipe *outlier* lainnya. Wei (2006) mendefinisikan model IO sebagai berikut:

$$\begin{aligned} Y_t &= X_t + \frac{\theta(B)}{\varphi(B)} \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\varphi(B)} (a_t + \omega I_t^{(T)}) \end{aligned} \quad (2.36)$$

Efek AO hanya terjadi pada  $T$  observasi saja, sedangkan pada IO mempengaruhi seluruh observasi  $Y_{t,-1}, \dots$  melewati waktu  $T$  sepanjang memori dari sistem yang diberikan oleh  $\frac{\theta(B)}{\varphi(B)}$ .

iii. **Level Shift (LS)**

*Level Shift* merupakan kejadian yang mempengaruhi deret pada satu waktu tertentu dan memberikan efek suatu perubahan yang tiba-tiba dan permanen. Model *Level Shift* pada data runtun waktu dapat dinyatakan dengan (Wei 2006):

$$Y_t = X_t + \frac{1}{(1-B)} \omega_L I_t^{(T)} \quad (2.37)$$

iv. **Temporary Change (TC)**

*Temporary Change* adalah suatu kejadian dimana *outlier* menghasilkan efek awal pada waktu ke- $t$  sebesar  $\omega t$ , kemudian efek tersebut berkurang secara perlahan sesuai dengan besarnya  $\delta$ . Model TC dinyatakan dengan:

$$Y_t = X_t + \frac{1}{(1-\delta B)} \omega_L I_t^{(T)} \quad (2.38)$$

e. **Peramalan atau Forecast**

Tahapan terakhir yang dilakukan dalam analisis *time series* adalah tahap peramalan (Wei, 2006). Suatu model ARIMA dengan  $d = 0$  atau ARMA ( $p, q$ ) yang stasioner secara umum didefinisikan dalam bentuk:

$$\phi(B)Y_t = \theta(B)\alpha_t \quad (2.39)$$

atau dapat ditulis dalam representasi MA, yaitu :

$$Y_t = (B) = \alpha_t + \psi_1 \alpha_{t-1} + \psi_2 \alpha_{t-2} + \dots, \quad (2.40)$$

dimana,

$$(B) = \sum_{j=0}^{\infty} \psi_j B^j = \theta(B)/\phi(B), \quad (2.41)$$

dan  $\psi_0 = 1$ , Untuk  $t = n + l$ , kita mempunyai:

$$Y_{n+l} = \sum_{j=0}^{\infty} \psi_j \alpha_{n+l-j}, \quad (2.42)$$

dengan menggunakan ramalan minimum *Mean Square Error* akan diperoleh:

$$\hat{y}_n(l) = \psi_l \alpha_n + \psi_{l+1} \alpha_{n-1} + \psi_{l+2} \alpha_{n-2} + \dots. \quad (2.43)$$

$\hat{y}_n(l)$  biasa dibaca sebagai ramalan pada langkah ke- $l$  dari  $y_n$ , sehingga untuk kesalahan ramalan pada  $l$  langkah ke depan diperoleh :

$$e_n(l) = y_n(l) - \hat{y}_n(l) = \sum_{j=0}^{\infty} \psi_j \alpha_{n+l-j} \quad (2.44)$$

Error ramalan adalah saling independen dan kombinasi linear setelah waktu  $n$ . Untuk error ramalan pertama bisa ditulis:

$$e_n(1) = y_n(1) - \hat{y}_n(1) = \alpha_{n+1} \quad (2.45)$$

dimana:  $\hat{y}_n(1)$  adalah ramalan terbaik untuk  $y_{n+1}$ .

### 2.1.2 Neural Network (NN)

*Neural Network* (NN) atau jaringan saraf tiruan adalah sebuah system proses informasi yang memiliki karakteristik performa tertentu dalam jaringan saraf biologis. NN telah dikembangkan sebagai generalisasi model matematis dari kesadaran manusia atau saraf biologi, berdasarkan asumsi-asumsi sebagai berikut:


- Pemrosesan informasi terjadi pada banyak *simple element* yang disebut *neuron*.
- Sinyal dilewatkan di antara neuron di atas *connection link*.
- Masing-masing *connection link* memiliki bobot yang dikalikan dengan sinyal yang ditransmisi.
- Masing-masing *neuron* menggunakan fungsi aktivasi (biasanya non-linear) pada *net input* (jumlahan sinyal input terboboti) untuk menentukan sinyal *output*.

Sebuah *neural network* digolongkan berdasarkan pola *connection* di antara neuron (disebut juga arsitektur), metode dalam menentukan bobot dari *connection* (disebut *training*, *learning* atau *algoritma*), dan fungsi aktivasi (Fausett, 1994).

Beberapa jenis desain neural networks antara lain *back-propagation* (*feed forward*), *recurrent network*, *self-organizing map*, *radial basis function network*, dan sebagainya. Terdapat beberapa komponen yang harus dipertimbangkan dalam metode NN modeling, yaitu *neuron*, *layer*, fungsi aktivasi, dan bobot. Komponen-komponen ini akan sangat mempengaruhi dalam menentukan model NN karena pembentukan model NN didasarkan pada jumlah *neuron* dalam *input layer*, *hidden layer*, dan *output layer* serta fungsi aktivasi (Kusumadewi, 2004).

*Multilayer Perceptron* adalah *Neural Network* yang terdiri dari beberapa *layer neuron* (*computing unit*) yang dihubungkan secara hirarkis secara *Feed Forward*. Menurut Jha (2007), *Multilayer Perceptron* :

- a. Memiliki beberapa input
- b. Memiliki satu atau beberapa *hidden layer* dengan beberapa unit
- c. *Input layer* menggunakan fungsi kombinasi linear
- d. *Hidden layer* secara umum menggunakan fungsi aktivasi sigmoid
- e. Dapat memiliki satu atau beberapa *output* dengan beberapa fungsi aktivasi
- f. Koneksi terdiri dari *input layer* dengan *hidden layer* pertama, ke *hidden layer* berikutnya sampai *hidden layer* terakhir, dan koneksi *hidden layer* terakhir dengan *output layer*.



**Gambar 2.1** Multilayer Perceptron dengan Dua Hidden Layer

*Multilayer perceptron* menggunakan beberapa teknik *learning*, diantaranya yang paling populer adalah algoritma *back-propagation*. Arsitektur *neural network back-propagation* adalah desain hirarkis yang berisi node pada tiap *layer* yang saling terkoneksi secara penuh. Pada algoritma *back-propagation* memungkinkan jika ada *error* pada *output*, maka akan dikembalikan ke *node* pada *hidden layer* untuk kemudian memberikan bobot yang berbeda pada *node* tersebut untuk selanjutnya dilakukan *update* pada node tersebut untuk selanjutnya dilakukan *update* pada node *output layer*. Salah satu hal penting dalam mendesain arsitektur *back-propagation* adalah memilih fungsi aktivasi *sigmoidal*, dimana fungsi tersebut telah digunakan oleh banyak para peneliti.

Fungsi sigmoid :

$$f(x_j) = f(\alpha_j + \sum_{i=1}^k w_{ij} y_i) \quad (2.38)$$

(Jha, 2007).

FFNN telah menunjukkan keberhasilannya dalam pengaplikasian terhadap penyelesaian masalah yang kompleks dengan memberikan pembelajaran *supervised* melalui algoritma yang sangat populer, yaitu *back-propagation algorithm* (Haykin, 2009). Algoritma *back-propagation* berdasarkan data training  $\{(n);(n)\}$  dengan batas atas  $N$  dan batas bawah  $n-1$  dapat diuraikan sebagai berikut (Haykin, 2009):

1. Inisialisasi. Dengan mengasumsikan bahwa tidak ada informasi sebelumnya yang tersedia dan pilih secara acak dengan nilai yang sangat kecil.
2. Jadikan *data training* sebagai input. Pada *network*, tentukan siklus pelatihan (*epoch*) dari *data training*. Untuk setiap *set data training*, lakukan proses komputasi *forward* dan *backward* pada langkah 3 dan 4.
3. Komputasi *forward*. Misalkan *data training* dinotasikan sebagai  $((n),(n))$ , dengan input berupa vektor  $x(n)$  pada *input layer* dan vektor respon  $d(n)$  yang berada pada *output layer*. Hitung penjumlahan tertimbang dan fungsi sinyal dari network secara maju *layer* demi *layer* yang dilalui. Penjumlahan tertimbang  $(l)(n)$  untuk *neuron*  $j$  pada *layer*  $l$  adalah:

$$(l)(n) = \sum_{i=1}^{m_0} w_{ij}^{(l)} y_i^{(l-1)}(n) \quad (2.39)$$

dimana  $y_i^{(l-1)}(n)$  adalah output dari fungsi sinyal *neuron*  $i$  pada layer sebelumnya  $l-1$  pada iterasi ke- $n$ , dan  $w_{ij}^{(l)}$  adalah penimbang dari *neuron*  $i$  pada layer  $l$  yang berasal dari *neuron*  $j$  pada layer  $l-1$ . Untuk  $i=0$ , diperoleh  $y_0^{(l-1)}(n)=+1$  dan  $w_{0j}^{(l)}(n)=b_j^{(l)}(n)$  yang merupakan bias *neuron*  $j$  pada layer  $l$ . Dengan asumsi menggunakan fungsi *sigmoid*, sinyal output *neuron*  $j$  pada layer  $l$  adalah:

$$(l)=(v_j(n)), \quad (2.40)$$

Jika *neuron*  $j$  berada pada *hidden layer* pertama ( $l=1$ ), tentukan:

$$(0)(n)=(n), \quad (2.41)$$

dimana  $x_j(n)$  adalah elemen ke- $j$  dari vektor input  $x(n)$ .

Jika *neuron j* berada pada *output layer* ( $l=L$ ), dimana  $L$  merupakan kedalaman dari *network*, tentukan:

$$d_j(L) = d_j(n) \quad (2.42)$$

Menghitung nilai error:

$$e_j(n) = d_j(n) - o_j(n), \quad (2.43)$$

dimana  $d_j(n)$  merupakan elemen ke  $j$  dari vektor respon  $d(n)$ .

4. Komputasi *backward*. Hitung nilai  $\delta$  (gradien lokal), yang didefinisikan sebagai berikut:

$$d_j(L) = \begin{cases} d_j(L) \phi_j'(v_j(L)) & \text{Untuk neuron } j \text{ pada output } L \\ \phi_j'(v_j(L)) \sum_k \delta_k(l+1) w_{kj}(l+1) & \text{Untuk neuron } j \text{ pada output } l \end{cases} \quad (2.44)$$

Perbarui penimbang pada *layer l* berdasarkan:

$$w_{ij}(l+1) = w_{ij}(l) + \alpha [w_{ij}(l)(n-1)] + \eta \delta_j(l)(n) y_i(l-1)(n),$$

dimana  $n$  merupakan parameter *learning-rate* dan  $\alpha$  adalah konstanta.

5. Iterasi. Lakukan iterasi terhadap komputasi *forward* dan *backward* pada langkah 3 dan 4 dengan memberikan *epoch* yang baru pada data *training* sampai kriteria penghentian yang dipilih terpenuhi.

### 2.1.2 Pemodelan *Hybrid* ARIMAX-NN

ARIMAX adalah model linear, sehingga model-model ini tidak dapat membaca pola data non-linear, tetapi model ini mudah untuk diinterpretasikan. Sebaliknya, NN adalah salah satu model non-linear yang baik, akan tetapi hasilnya sulit untuk diinterpretasikan. Pemodelan *Hybrid* ini dimaksudkan untuk menambah keakuratan peramalan data dari model linear yang mudah diinterpretasikan dengan mengkombinasikan model linear dengan model non-linear. Struktur dari pemodelan *Hybrid* ini adalah :

$$\dot{Z}_t = L_t + R_t \quad (2.45)$$

dimana  $L_t$  adalah komponen linear dan  $R_t$  adalah komponen non-linear.

**a. Uji Terasvirta**

Uji non-linearitas data dapat digunakan dengan Uji Terasvirta. Uji Terasvirta termasuk dalam kelompok uji Lagrange Multiplier (LM) dengan pendekatan ekspansi Taylor yang menggunakan statistik uji  $\chi^2$  dengan derajat bebas  $v$ . Prosedur uji Terasvirta dijelaskan sebagai berikut (Terasvirta, Lin, & Granger, 1993):

- i. Meregresikan  $Y_t$  pada  $Y_{t-1}, \dots, Y_{t-p}$  dengan konstan 1 dan menghitung nilai-nilai residual  $\hat{u}_t$ .
- ii. Meregresikan  $\hat{u}_t$  pada  $Y_{t-1}, \dots, Y_{t-p}$  dengan konstan 1 dan  $v$  prediktor tambahan suku kuadratik dan kubik yang merupakan hasil dari pendekatan ekspansi Taylor.
- iii. Menghitung koefisien determinasi ( $R^2$ ) dari regresi pada langkah sebelumnya.
- iv. Menghitung statistik uji  $\chi^2 = nR^2$  dengan  $n$  adalah jumlah pengamatan. Hipotesis yang digunakan adalah sebagai berikut:

$H_0$  : model linear

$H_1$  : model non-linear

Statistik uji  $\chi^2$  mengikuti distribusi  $\chi_v^2$ , keputusan tolak  $H_0$  jika  $p$ -value dari statistik uji  $\chi^2$  kurang dari taraf nyata /  $\alpha$ .

**b. Pemilihan Model Terbaik**

Pemilihan model terbaik menggunakan kriteria *in-sample* dan *out-sample* dengan membandingkan nilai *Root Mean Square Error Prediction* (RMSEP). Formula dari perhitungan RMSEP adalah sebagai berikut:

$$\text{RMSEP} = \sqrt{\frac{\sum_{l=1}^m (z_{t+l} - \hat{z}_t(l))^2}{m}} \quad (2.46)$$

dengan:

$z_t$  = vektor deret *output* pada waktu ke- $t$ ,

$\hat{z}_t$  = vektor estimasi deret *output* pada waktu ke- $t$ ,

$m$  = jumlah ramalan yang dilakukan.

(Lee & Suhartono, 2010).

## **2.2 Tinjauan Non Statistik**

Tinjauan non statistik yang akan dibahas pada penelitian ini menjelaskan mengenai beberapa produk yang dihasilkan PT. Pertamina (Persero) Region V Surabaya.

### **2.2.1 Pertamax**

Pertamax adalah bahan bakar minyak andalan Pertamina. Pertamax, seperti halnya premium adalah produk BBM dari pengolahan minyak bumi. Pertamax dihasilkan dengan penambahan zat aditif dalam proses pengolahannya di kilang minyak. Pertamax pertama kali diluncurkan pada tanggal 10 Desember 1999 sebagai pengganti premix 1994 dan Super TT 1998 karena unsur MTBE yang berbahaya bagi lingkungan. Selain itu, Pertamax memiliki beberapa keunggulan dibandingkan dengan Premium. Pertamax direkomendasikan untuk kendaraan yang memiliki kompresi 9.1-10.1, terutama yang telah menggunakan teknologi setara dengan *Electronic Fuel Injection* (EFI) dan *catalytic converters* (pengubah katalitik).

Keunggulan pertamax :

- a. Bebas timbal.
- b. Oktan atau *Research Octane Number* (RON) yang lebih tinggi dari Premium, dan Peralite.
- c. Karena memiliki oktan tinggi, maka Pertamax bisa menerima tekanan pada mesin berkompresi tinggi, sehingga dapat bekerja dengan optimal pada gerakan piston. Hasilnya, tenaga mesin yang menggunakan Pertamax lebih maksimal, karena BBM digunakan secara optimal. Sedangkan pada mesin yang menggunakan Premium, BBM terbakar dan meledak, tidak sesuai dengan gerakan piston. Gejala inilah yang dikenal dengan 'knocking' atau mesin 'ngelitik'.

(Pertamina, 2017).



### 2.2.2 Pertalite

Pertalite adalah varian bahan bakar terbaru Pertamina yang telah hadir di 34 Kota atau Kabupaten. Pertalite diluncurkan tanggal 24 Juli 2015 sebagai varian baru bagi konsumen yang menginginkan BBM dengan kualitas di atas premium, tetapi dengan harga yang lebih murah daripada Pertamax, bahan bakar jenis ini menjadi penengah antara premium dan Pertamax. Memiliki *level research octane number* (RON) 90, Pertalite membuat pembakaran pada mesin kendaraan dengan teknologi terkini lebih baik dibandingkan dengan premium yang memiliki RON 88. Pertalite sesuai untuk digunakan kendaraan bermotor roda dua hingga kendaraan *multi purpose vehicle* ukuran menengah.

Keunggulan Pertalite :

a. *Durability*

Pertalite dapat dikategorikan sebagai bahan bakar kendaraan yang memenuhi syarat dasar durability atau ketahanan, dimana BBK ini tidak akan menimbulkan gangguan serta kerusakan mesin, karena kandungan oktan 90 lebih sesuai dengan perbandingan kompresi kebanyakan kendaraan bermotor yang beredar di Indonesia. Kandungan aditif detergent, anti korosi, serta pemisah air pada Pertalite akan menghambat proses korosi dan pembentukan deposit di dalam mesin.

b. *Fuel Economy*

Kesesuaian oktan 90 Pertalite dengan perbandingan kompresi kebanyakan kendaraan beroperasi sesuai dengan rancangannya. Perbandingan Air Fuel Ratio yang lebih tinggi dengan konsumsi bahan bakar menjadikan kinerja mesin lebih optimal dan efisien untuk menempuh jarak lebih jauh karena biaya operasi bahan bakar dalam Rp/Km akan lebih hemat.

c. *Performance*

Kesesuaian angka oktan Pertalite dan aditif yang di kandunginya dengan spesifikasi mesin akan menghasilkan performa mesin yang jauh lebih baik dibandingkan ketika menggunakan oktan 88. Hasilnya adalah tarikan lebih enteng, kecepatan yang lebih tinggi serta emisi gas buang yang lebih bersih.

Komposisi bahan untuk membuat pertalite adalah nafta yang memiliki RON 65-70, agar RON-nya menjadi RON 90 maka dicampurkan HOMC (*High Octane Mogas Component*), HOMC bisa juga disebut Pertamina, campuran HOMC yang memiliki RON 92-95, selain itu juga ditambahkan zat aditif EcoSAVE. Zat aditif EcoSAVE ini bukan untuk meningkatkan RON tetapi agar mesin menjadi bertambah halus, bersih dan irit.

Keterangan :

- a. Nafta adalah material yang memiliki titik didih antara gasolin dan kerosin yang digunakan untuk :
  1. Pelarut dry cleaning (pencuci)
  2. Pelarut karet
  3. Bahan awal etilen
  4. Bahan bakar jet dikenal sebagai JP-4
- b. HOMC yaitu merupakan produk naphtha (komponen minyak bumi) yang memiliki struktur kimia bercabang dan ring (lingkar) berangka oktan tinggi (daya bakar lebih sempurna dan instant cepat), oktan di atas 92, bahkan ada yang 95, sampai 98 lebih. Kebanyakan merupakan hasil olah lanjut Naphtha jadi berangka oktane tinggi atau hasil perengkahan minyak berat menjadi HOMC. Terbentuknya oktan number tinggi adalah hasil perengkahan katalitik ataupun sintesis catalytic di reaktor kimia Unit kilang RCC/FCC/RFCC atau Plat Forming atau proses polimerisasi katalitik lainnya (Pertamina, 2017).

*“Halaman ini sengaja dikosongkan”*

## BAB III

### METODE PENELITIAN

#### 3.1 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa data bulanan penjualan pertamax pada Januari tahun 2010 hingga Juni 2017, yang diperoleh dari PT. Pertamina (Persero) Region V Surabaya. Data yang digunakan dibagi menjadi dua bagian yaitu data Januari 2010 hingga Juli 2016 sebagai data *in-sample* (79 data) dan data Agustus 2016 hingga Juli 2017 sebagai data *out-sample* (12 data).

#### 3.2 Variabel Penelitian

Variabel penelitian yang digunakan adalah sebagai berikut :

$Y_t$  : data penjualan produk pertamax ,

$$X_{1,t} = \begin{cases} 0, & t < \text{Juli 2015}, t = 1, 2, \dots, 66 \\ 1, & t \geq \text{Juli 2015}, t = 67, 68, \dots, 91 \end{cases}$$

$X_{1,t}$  merupakan *dummy* periode sejak diluncurkan produk pertalite.

$$X_{2,t} = \begin{cases} 0, & t < \text{Juli 2015}, t = 1, 2, 3, \dots, 66 \\ X_{2,t}, & t \geq \text{Juli 2015}, t = 67, 68, \dots, 91 \end{cases}$$

$X_{2,t}$  merupakan data penjualan produk pertalite.

#### 3.3 Struktur Data

Struktur data yang digunakan terdiri dari data penjualan produk pertamax dan pengaruh penjualan pertamax yaitu *dummy* periode sejak diluncurkan produk pertalite dan data penjualan produk pertalite yang mengakibatkan penjualan produk pertamax cenderung menurun. Struktur data akan disajikan pada Tabel 3.1 sebagai berikut:

**Tabel 3. 1** Struktur Data Penjualan Pertamina Dengan Pengaruh Produk Pertamina

Bulan-Tahun	t	$Y_t$	$X_{1,t}$	$X_{2,t}$
Jan-2010	1	$Y_1$	0	0
Feb-2010	2	$Y_2$	0	0
Mar-2010	3	$Y_3$	0	0
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
Juni-2015	66	$Y_{66}$	0	0
Juli-2015	67	$Y_{67}$	1	$X_{2,67}$
Agustus-2015	68	$Y_{68}$	1	$X_{2,68}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
Mei-2017	89	$Y_{89}$	1	$X_{2,89}$
Juni-2017	90	$Y_{90}$	1	$X_{2,90}$
Juli-2017	91	$Y_{91}$	1	$X_{2,91}$

### 3.4 Langkah-langkah Analisis

Metode analisis yang digunakan untuk menentukan model peramalan penjualan Pertamina pada periode mendatang menggunakan metode ARIMAX, NN, dan *Hybrid* ARIMAX-NN.

Langkah-langkah analisis dengan metode ARIMAX dapat dijelaskan sebagai berikut :

- Mengumpulkan data volume penjualan Pertamina pada Januari 2010-Juli 2017.
- Memeriksa stasioneritas data *in-sample* penjualan Pertamina.
- Memodelkan data *in-sample* penjualan Pertamina dengan memasukkan variabel dummy, lalu dilanjutkan ke model ARIMAX, serta melakukan pemeriksaan signifikansi parameter, asumsi *white noise*, dan asumsi berdistribusi normal.
- Apabila ada lebih dari satu model ARIMAX, maka perlu membandingkan dan memilih berdasarkan nilai RMSEP terkecil.

Langkah-langkah analisis dengan metode *Feedforward Neural Network* (FFNN) dapat dijelaskan sebagai berikut :

- Mengumpulkan data volume penjualan Pertamina pada Januari 2010-Juli 2017.


- b. Menentukan variabel input untuk pemodelan *Feedforward Neural Network* (FFNN) dilihat dari lag berdasarkan plot ACF dan PACF dari data.
- c. Melakukan pemodelan FFNN 1 sampai 2 *hidden layer* dengan fungsi aktivasi sigmoid.
- d. Memilih model FFNN terbaik dengan melihat nilai RMSEP terkecil.

Langkah-langkah analisis dengan metode *Hybrid ARIMAX-FFNN* dapat dijelaskan sebagai berikut :

- a. Melakukan pemodelan ARIMAX dan didapatkan nilai *forecast* dan residual dari model ARIMAX, dimana nilai residual model ARIMAX sebagai input NN.
- b. Melakukan pemodelan FFNN 1 sampai 2 *hidden layer* dengan fungsi aktivasi sigmoid dan didapatkan nilai *forecast*.
- c. Melakukan pemodelan *Hybrid ARIMAX-FFNN*.
- d. Memilih model *Hybrid ARIMAX-FFNN* terbaik dengan melihat nilai RMSE *in sample* dan *out sample* terkecil.
- e. Karena ada lebih dari satu model *hybrid ARIMAX-FFNN* yang didapat dari beberapa jumlah yang berbeda, maka perlu membandingkan dan memilih berdasarkan nilai RMSEP terkecil sehingga didapatkan model terbaik.


Setelah mendapatkan nilai RMSEP dari ketiga metode, maka dipilih berdasarkan nilai RMSEP terkecil dan melakukan ramalan penjualan pertamax bulan Agustus 2017-Juli 2018 dari model terbaik yang telah dipilih.

Diagram alir atau *flow chart* langkah-langkah analisis menggunakan metode ARIMAX dapat dijelaskan pada Gambar 3.1.




**Gambar 3.1** Flow Chart Langkah-langkah Analisis Metode ARIMAX

Diagram alir atau *flow chart* langkah-langkah analisis menggunakan metode *Feedforward Neural Network* dapat dijelaskan pada Gambar 3.2.



**Gambar 3. 2** *Flow Chart* Langkah-langkah Analisis Metode *Feedforward Neural Network*


Diagram alir atau *flow chart* langkah-langkah analisis menggunakan metode *Hybrid ARIMAX-FFNN* dijelaskan pada Gambar 3.3.



**Gambar 3. 3** *Flow Chart* Langkah-langkah Analisis Metode *Hybrid ARIMAX-FFNN*




Arsitektur tahap 1 pada analisis menggunakan metode *Hybrid* ARIMAX-FFNN dijelaskan pada Gambar 3.4.



**Gambar 3.4** Ilustrasi Pembentukan Model Metode *Hybrid* ARIMAX-FFNN Tahap 1

Arsitektur tahap 2 pada analisis menggunakan metode *Hybrid* ARIMAX-FFNN dijelaskan pada Gambar 3.5.



**Gambar 3.5** Ilustrasi Pembentukan Model Metode *Hybrid* ARIMAX-FFNN Tahap 2

*“Halaman ini sengaja dikosongkan”*


## BAB IV

### ANALISIS DAN PEMBAHASAN

Analisis data dilakukan terhadap pengaruh penjualan pertalite terhadap pertamax di PT. Pertamina (Persero) Regional V Surabaya untuk mengetahui ramalan penjualan produk bahan bakar pertamax menggunakan metode ARIMAX, *Feedforward Neural Network* (FFNN) dan *Hybrid ARIMAX-Feedforward Neural Network* (FFNN). Berikut penjelasan masing-masing metode peramalan data penjualan pengaruh pertalite terhadap pertamax di PT. Pertamina (Persero) Regional V Surabaya.

#### 4.1 Analisis Data Pengaruh Penjualan Pertalite Terhadap Pertamax Pada Wilayah Regional V Surabaya

Identifikasi adanya pengaruh penjualan produk pertalite terhadap penjualan produk pertamax dapat ditunjukkan dengan plot pada Gambar 4.1 sebagai berikut.



**Gambar 4. 1** Plot Penjualan Pertalite Terhadap Pertamax Pada Januari 2010- Juli 2017

Gambar 4.1 dapat dilihat bahwa periode sejak diluncurkan produk pertalite pada Juli 2015, penjualan pertamax masih lebih tinggi dibandingkan produk pertalite. Sejak diluncurkan produk pertalite, penjualan pertalite terus terjadi peningkatan hingga Juni 2016 penjualan produk pertamax lebih rendah

dibandingkan produk pertalite. Plot ini jelas menunjukkan adanya pengaruh penjualan produk pertalite terhadap produk pertamax.

Pengujian ANOVA untuk mengetahui adanya pengaruh penjualan bahan bakar pertalite terhadap pertamax secara serentak dapat ditampilkan pada Tabel 4.1 sebagai berikut :

**Tabel 4. 1** Pengujian ANOVA Pengaruh Penjualan Pertalite (kl) Terhadap Pertamax Serentak

Sumber	df	SS	MS	F	p_value
Regresi	2	1326222103	663111052	230,23	0,0000
Error	88	25346175	2880184		
Total	90	1579678278			

Tabel 4.1 dapat dilihat  $p\_value < \alpha$  yaitu  $0,000 < 0,05$  sehingga dapat disimpulkan bahwa adanya pengaruh signifikan penjualan bahan bakar pertalite terhadap penjualan pertamax. Pengujian juga dilakukan secara individu antara penjualan pertamax dengan *dummy* periode sejak diluncurkan pertalite dan volume penjualan pertalite yang ditampilkan pada Tabel 4.2 sebagai berikut :

**Tabel 4.2** Pengujian ANOVA Pengaruh Penjualan Pertalite (kl) Terhadap Pertamax Individu


Prediktor	Coef	SE Coef	F	p_value
Konstan	2143,7	208,9	10,26	0,000
Pertalite (kl)	0,29626	0,04865	6,09	0,000
Dummy	4506,9	725,8	6,21	0,000

Tabel 4.2 dapat dilihat variabel volume penjualan pertalite dan *dummy* sejak diluncurkan produk pertalite masing-masing mempunyai  $p\_value < \alpha$  yaitu  $0,000 < 0,05$  sehingga dapat disimpulkan bahwa adanya pengaruh signifikan volume penjualan bahan bakar pertalite dan *dummy* sejak diluncurkan pertalite terhadap penjualan pertamax.

## 4.2 Pemodelan Penjualan Pertamax dengan Metode ARIMAX


Dalam pemodelan penjualan pertamax dengan menggunakan metode ARIMAX, variabel eksogen yang digunakan adalah variabel non-metriks berupa variabel *dummy* periode penjualan produk pertalite, sedangkan variabel metriks berupa volume penjualan produk pertalite.

Sebelum melakukan pemodelan, perlu dilakukan identifikasi pola data dengan plot *time series*. Plot *time series* dari penjualan produk pertamax disajikan dalam Gambar 4.2 sebagai berikut.



**Gambar 4.2** Plot Penjualan Pertamax Pada Januari 2010 - Juli 2016


Berdasarkan Gambar 4.2 dapat kita lihat bahwa data *trend* naik artinya terdapat kenaikan penjualan pertamax yang signifikan mulai Agustus 2014 dan belum berada di sekitar rata-rata, maka dapat dikatakan data belum stasioner dalam *mean*.



**Gambar 4.3** Plot ACF (a) dan PACF (b) Penjualan Produk Pertamax Pada Januari 2010-Juli 2016

Pola data pada Gambar 4.3 menunjukkan bahwa data penjualan pertamax belum dalam kondisi stasioner dalam *mean*, karena lag-lag dalam plot masih turun secara lambat. Dalam hal ini, ketidakstasioneran lebih didominasi oleh sebab adanya kenaikan yang signifikan pada penjualan bahan bakar pertamax. Selanjutnya dilakukan identifikasi stasioneritas dalam *varians*. Pengecekan

stasioneritas data dalam varians dilakukan dengan melihat plot Box-Cox seperti pada Gambar 4.4 sebagai berikut.



**Gambar 4.4** Plot Box-Cox Penjualan Produk Pertamina Pada Januari 2010 - Juli 2016

Plot Box-Cox pada Gambar 4.4 menunjukkan data belum stasioner terhadap varians karena *rounded value*-nya belum bernilai 1 ( $\lambda = 0,5$ ), serta rentang *lower* dan *upper CL* nya juga belum melewati 1. Berdasarkan nilai *lamda*-nya, maka data perlu ditransformasi dengan menggunakan transformasi logaritma natural ( $\sqrt{Z_t}$ ), sehingga:

$$Y_t = \sqrt{Z_t} \text{ dengan } Y_t \text{ yang telah stasioner dalam varians.}$$


Untuk memperkuat adanya pola data reguler atau musiman, maka dilakukan pengujian *Augmented Dickey Fuller* (ADF) yang akan ditampilkan pada Tabel 4.3 sebagai berikut :

**Tabel 4.3** Hasil Pengujian ADF Penjualan Peralite (kl) Terhadap Pertamina

Prediktor	Type	Lag	Tau ( $\tau$ )	p_value
Non-seasonal	(1) Zero Mean	1	-4,71	< 0,0001
	(2) Single Mean	1	-5,02	0,0001
	(3) Trend	1	-5,18	0,0003
Seasonal	(1) Zero Mean	12	0,20	0,714
	(2) Single Mean	12	-0,81	0,8099
	(3) Trend	12	-1,28	0,8849


Tabel 4.3 menunjukkan hasil pengujian *Augmented Dickey Fuller* (ADF) dapat dilihat bahwa perlu dilakukan *differencing* reguler 1 karena *p-value* < 0,005 dan tidak perlu dilakukan *differencing* untuk seasonal (musiman) karena

$p\text{-value} < 0,005$ . Hal ini memperkuat hasil dari plot ACF dan PACF jika tidak perlu dilakukan *differencing* terhadap musiman. Maka sebelum kita memodelkan data dengan ARIMAX, kita lakukan *differencing* data terlebih dahulu.



**Gambar 4.5** Plot *Differencing* Penjualan Produk Pertamina Pada Januari 2010 - Juli 2016


Gambar 4.5 dapat kita lihat bahwa setelah dilakukan *differencing*, data telah berada di sekitar rata-rata, maka dapat dikatakan data sudah stasioner dalam *mean*.



**Gambar 4.6** Plot ACF (a) dan PACF (b) Setelah Dilakukan *Differencing* Penjualan Produk Pertamina Pada Januari 2010 - Juli 2016

Gambar 4.6 adalah hasil dari proses *differencing* menunjukkan bahwa kondisi data telah stasioner, dimana pada plot ACF dan PACF terdapat lag yang signifikan yaitu lag 1. Berdasarkan analisis tersebut, maka didapatkan dugaan model untuk penjualan pertamax adalah ARIMA (1,1,0) dan ARIMA (0,1,1).





**Gambar 4.7** Plot Box-Cox Setelah Dilakukan *Differencing* Penjualan Produk Pertamax Pada Januari 2010 - Juli 2016

Plot Box-Cox pada Gambar 4.7 menunjukkan data telah stasioner terhadap varians karena *rounded value*-nya telah bernilai 1 ( $\lambda = 1$ ), serta rentang *lower* dan *upper* CL nya juga telah melewati 1. Berdasarkan analisis tersebut, maka didapatkan hasil estimasi dan pengujian signifikan parameter data penjualan pertamax sebagai berikut:

**Tabel 4.4** Estimasi dan Pengujian Signifikansi Parameter Model ARIMAX Data Pertamax

Model	Variabel	Parameter	Estimasi	t	p-value
ARIMAX (1,1,0)	$Z_{t-1}$	$\phi_1$	0,32816	2,84	0,0058
	$X_{1,t}$	$\beta_1$	0,36294	3,17	0,0022
	$X_{2,t}$	$\beta_2$	74,48486	0,16	0,8706
ARIMAX (0,1,1)	$a_{t-1}$	$\theta_1$	-0,23865	-1,97	0,0531
	$X_{1,t}$	$\beta_1$	0,33970	3,18	0,0021
	$X_{2,t}$	$\beta_2$	-58,30678	-0,12	0,9052

Hasil estimasi dan pengujian signifikansi parameter model ARIMAX tertera pada Tabel 4.4. Berdasarkan hasil estimasi terdapat beberapa parameter yang tidak signifikan karena ada  $p\text{-value} > 0,05$ . Selanjutnya dilakukan pemeriksaan asumsi dari kedua model ARIMA, apakah *residual* telah memenuhi asumsi *white noise*.

**Tabel 4.5** Uji Asumsi Residual *White Noise* Dugaan Model ARIMAX Data Penjualan Pertamax

Model	Hingga Lag	Chi-Square	df	p-value
ARIMAX (1,1,0)	6	7,23	5	0,2039
	12	11,91	11	0,3707
	18	14,88	17	0,6043
	24	16,27	23	0,8435
	30	18,68	29	0,9291
	36	21,55	35	0,9636

**Tabel 4.6** Uji Asumsi Residual *White Noise* Dugaan Model ARIMAX Data Penjualan Pertamax (Lanjutan)

Model	Hingga Lag	Chi-Square	df	p-value
ARIMAX (0,1,1)	6	9,64	5	0,0860
	12	15,30	11	0,1694
	18	18,77	17	0,3418
	24	20,10	23	0,6357
	30	21,91	29	0,8238
	36	24,01	35	0,9195

Berdasarkan hasil pengujian *white noise* menggunakan uji Ljung-Box diperoleh hasil bahwa *residual* kedua metode ARIMAX memenuhi asumsi *white noise* karena *p-value* > 0,05. Selanjutnya dilakukan pemeriksaan asumsi dari kedua model ARIMAX, apakah *residual* telah memenuhi asumsi distribusi normal.

**Tabel 4.7** Uji Asumsi Distribusi Normal Dugaan Model ARIMAX Data Penjualan Pertamax

Model	Kolmogorov-Smirnov	p-value
ARIMAX (1,1,0)	0,10889	0,0220
ARIMAX (0,1,1)	0,115922	0,0102

Tabel 4.7 menunjukkan bahwa pengujian terhadap residual belum memenuhi asumsi distribusi normal karena *p-value* < 0,05. Pemeriksaan model terbaik dilakukan dengan memilih nilai AIC, SBC, RMSE-in, dan RMSEP minimum dapat dilihat pada Tabel 4.8 sebagai berikut:

**Tabel 4.8** Kriteria Kebaikan Dugaan Model ARIMAX Data Penjualan Pertamax

Model	AIC	SBC	RMSE-in	RMSEP
ARIMAX (1,1,0)	1181,242	1188,312	449,571	1613
ARIMAX (0,1,1)	1183,245	1190,315	468,301	1521

Tabel 4.8 menunjukkan bahwa dari keempat nilai kriteria yang digunakan untuk memilih model terbaik adalah dengan melihat nilai AIC, SBC, RMSE-in, dan RMSEP minimum yaitu model ARIMAX (1,1,0), tetapi uji asumsi residual belum memenuhi berdistribusi normal. Tidak normalnya residual ini diduga disebabkan adanya *outlier* di dalam data yang digunakan. *Outlier* pada model tersebut ditemukan pada data ke-berapa dapat dilihat pada Tabel 4.9 sebagai berikut:

**Tabel 4.9** Pendeteksian *Outlier* Pada Model ARIMAX

Data ke-	Jenis <i>Outlier</i>	p-value
61	<i>Level Shift</i>	0,0194
66	<i>Additive Outlier</i>	0,0064
72	<i>Level Shift</i>	< 0,0001
73	<i>Level Shift</i>	< 0,0001

Tabel 4.9 merupakan data *outlier* yang terdapat pada model ARIMAX (1,1,0) dengan masing-masing *p-value* < 0,05. Sehingga, dapat dikatakan *outlier* yang terjadi berpengaruh pada data yang digunakan. Kejadian terjadinya *outlier* akan dijelaskan pada Tabel 4.10 sebagai berikut:

**Tabel 4.10** Penjelasan Data Terjadinya *Outlier*

Data ke-	Jenis <i>Outlier</i>	Bulan, Tahun	Kejadian
61	<i>Level Shift</i>	Januari, 2015	Terjadi penurunan harga, penjualan meningkat
66	<i>Additive Outlier</i>	Juni, 2015	1 bulan sebelum terjadinya lebaran
72	<i>Level Shift</i>	Desember, 2015	Terjadi penurunan harga
73	<i>Level Shift</i>	Januari, 2016	Terjadi penurunan harga

Keberadaan *outlier* yang menyebabkan tidak normalnya residual model ini diatasi dengan memasukkan data *outlier* ke dalam model peramalan. Hasil estimasi dan pengujian signifikansi parameter dapat dilihat Tabel 4.11 sebagai berikut:

**Tabel 4.11** Estimasi dan Pengujian Signifikansi Parameter Model ARIMAX

Pada Data Penjualan Pertamina dengan Penambahan *Outlier*

Model	Variabel	Parameter	Estimasi	Std. Error	t-value	p-value
ARIMAX (1,1,0)	$Z_{t-1}$	$\phi_1$	0,44056	0,10770	4,09	0,0001
	$X_{1,t}$	$\beta_1$	0,32313	0,10195	3,17	0,0023
	$X_{2,t}$	$\beta_2$	-1648,4	644,20477	-2,56	0,0126
	LS73	$\beta_3$	913,35894	280,73393	3,25	0,0017
	LS72	$\beta_4$	653,44574	279,34010	2,34	0,0221
	AO66	$\beta_5$	-1365,3	387,08884	-3,53	0,0007
	LS61	$\beta_6$	771,75284	215,62549	3,58	0,0006

Pengujian parameter menunjukkan bahwa seluruh parameter yang digunakan dalam model telah signifikan dengan *p-value* untuk seluruh parameter yang bernilai kurang dari 0,05. Langkah selanjutnya adalah melakukan pengujian asumsi *white noise* untuk residual hasil pemodelan seperti pada Tabel 4.12 sebagai berikut:

**Tabel 4.12** Uji Asumsi Residual *White Noise* Dugaan Model ARIMAX

Data Penjualan Pertamina dengan Menambahkan *Outlier*

Model	Hingga Lag	Chi-Square	df	p-value
ARIMAX (1,1,0)	6	0,1454	5	0,1454
	12	0,0977	11	0,0977
	18	0,0675	17	0,0675
	24	0,1828	23	0,1828
	30	0,2741	29	0,2741
	36	0,2426	35	0,2426

Tabel 4.12 menunjukkan bahwa residual model ARIMAX (1,0,0) dengan deteksi *outlier* telah mencapai kondisi *white noise*, ditunjukkan dengan *p-value* yang bernilai lebih dari 0,05. Untuk pengujian asumsi normalitas data penjualan pertamax ditunjukkan pada Tabel 4.13 sebagai berikut:

**Tabel 4.13** Uji Asumsi Distribusi Normal Dugaan Model ARIMAX (1,1,0)  
Pada Data Penjualan Pertamax dengan Menambahkan *Outlier*

Model	Kolmogorov-Smirnov	p-value
ARIMAX (1,1,0)	0,09993	0,0525

Hasil pengujian normalitas residual model tersebut juga telah menunjukkan bahwa residual model berdistribusi normal dengan *p-value* yang bernilai lebih dari 0,05. Hasil pengujian terhadap residual menunjukkan bahwa model yang digunakan telah memenuhi asumsi *white noise* dan distribusi normal dengan nilai *error* AIC, SBC, RMSE-*in*, dan RMSEP sebagai berikut:

**Tabel 4.14** Nilai AIC, SBC, RMSE-*in*, dan RMSEP Model ARIMAX Data Penjualan Pertamax dengan Menambahkan *Outlier*

Model	AIC	SBC	RMSE- <i>in</i>	RMSEP
ARIMAX (1,1,0)	1158,124	1174,621	368,273	1411

Tabel 4.14 menunjukkan bahwa model ARIMAX (1,1,0) dengan menambahkan *outlier* didapatkan nilai AIC, SBC, RMSE-*in*, dan RMSEP masing-masing sebesar 1158,124; 1174,621; 368,273; dan 1411. Sehingga persamaan matematis yang diperoleh sebagai berikut:


$$(1 - 0,44056B)Z_t = 0,32313 X_{1,t} - 1648,4 X_{2,t} + 771,75284 I_{S,t}^{61} - 1365,3 I_{A,t}^{66} + 653,44574 I_{S,t}^{72} + 913,35894 I_{S,t}^{73} + \frac{1}{(1-B)} a_t$$

$$Z_t - 0,44056Z_{t-1} = 0,32313 X_{1,t} - 1648,4 X_{2,t} + 771,75284 I_{S,t}^{61} - 1365,3 I_{A,t}^{66} + 653,44574 I_{S,t}^{72} + 913,35894 I_{S,t}^{73} + \frac{1}{(1-B)} a_t$$

$$Z_t = 0,44056\hat{Z}_{t-1} + 0,32313 X_{1,t} - 1648,4 X_{2,t} + 771,75284 I_{S,t}^{61} - 1365,3 I_{A,t}^{66} + 653,44574 I_{S,t}^{72} + 913,35894 I_{S,t}^{73} + \frac{1}{(1-B)} a_t$$

Pada model ARIMAX dapat dijelaskan bahwa apabila volume penjualan pertalite naik sebesar satu satuan, maka volume penjualan pertamax akan turun sebesar 1648,4 kl dengan asumsi variabel lainnya konstan, dan seterusnya.

Untuk mengetahui adanya hubungan non-linear dari data dan lag-lagnya, maka dilakukan uji linearitas dengan plot non-linear data sebagai berikut:



**Gambar 4.8** Pola Non-Linear

Gambar 4.8 menunjukkan bahwa adanya pola non-linear karena plot tidak membentuk garis lurus dan untuk memperkuat alasan bahwa model non-linear sesuai pada data kebutuhan bahan bakar, maka ditunjukkan pula hasil pengujian Terasvirta yang dapat dilihat pada Tabel 4.15 sebagai berikut:

**Tabel 4.15** Hasil Uji Terasvirta

$\chi^2$	p-value
7,7511	0,02074

Tabel 4.15 menunjukkan bahwa adanya hubungan yang non-linear. Hasil pengujian linearitas ini dapat memperkuat alasan mengapa perlu dilanjutkan analisis non-linear *Feedforward Neural Network* (FFNN) dan *Hybrid ARIMAX-FFNN*.


### 4.3 Pemodelan Penjualan Pertamina dengan Menggunakan Metode *Feedforward Neural Network* (FFNN)

Untuk mendapatkan hasil peramalan yang diharapkan lebih akurat, *residual* dari model ARIMAX dari data penjualan pertamax akan dimodelkan kembali dengan menggunakan metode FFNN. Langkah awal pada pemodelan FFNN adalah menentukan input, jumlah *neuron* pada *hidden layer*, dan fungsi aktivasi apa yang digunakan. Penentuan input yang akan digunakan pada FFNN berdasarkan plot PACF pada model ARIMAX. Sesuai dengan model ARIMAX, maka input yang digunakan adalah hanya lag PACF yang signifikan yaitu lag 1. Jumlah *hidden nodes* yang digunakan pada FFNN *random* antara 1 – 30 *neuron* pada *hidden layer*-nya. Hasil *learning* FFNN kriteria model terbaik dapat dilihat pada Tabel 4.16 sebagai berikut:

**Tabel 4.16** Kriteria Model Terbaik *Feedforward Neural Network* (FFNN)

Model FFNN	Jumlah <i>Neuron</i>	Nilai Error	
		RMSE-in	RMSEP
1 <i>Hidden Layer</i>	1	481,2152	317,0833
	3	480,0886	318,1667
	5	481,481	309,5833
	6	486,2025	312,8333
	9	474,3924	312,1667
	10	482,7468	319,5833
	14	490,8481	308,5
	15	491,7595	291,25
	17	486,1013	312,1667
	19	482,8101	308,8333
	20	480,3165	313
	22	490,9747	312
	25	500,9114	290,4167
	27	489,8861	294,5
	29	499,5949	309
	30	486,557	305,8333
2 <i>Hidden Layer</i>	1-3	481,5063	314,3333
	2-6	481	321,6667
	5-2	481,443	316
	7-10	480,8987	318,9167
	6-8	479,3291	320,6667
	9-13	480,962	319,3333
	14-11	486,1266	298,0833
	18-22	484,0253	302,9167
	16-14	498,8228	278,8333
	20-25	501,8101	275,4167
	27-23	481,6456	319,9167
	25-30	611,481	<b>214,9167</b>
	30-30	482,1772	317

Tabel 4.16 menunjukkan bahwa kesesuaian pemilihan jumlah *neuron* pada *hidden layer* akan mempengaruhi nilai *sum of square error*. Kriteria pemilihan model terbaik dilihat dari nilai *sum of square error* yang minimum yaitu terdapat 2 *hidden layer* dengan masing-masing *neuron* tiap *hidden layer* 25 dan 30. Berikut ini arsitektur model FFNN (1-25-30-1):



**Gambar 4.9** Arsitektur FFNN (1-25-30-1)

Performa dari *neuron* sangat dipengaruhi oleh arsitektur secara keseluruhan diantaranya *input layer*, *hidden layer*, dan *output layer*. Secara umum arsitektur jaringan model FFNN dapat dimodelkan sesuai dengan fungsi aktivasi sigmoid pada *hidden layer* dan fungsi linear pada *output*.

Dengan demikian hasil estimasi *learning Feedforward Neural Network* (FFNN) sebagai berikut:

**Tabel 4.17** Estimasi Parameter *Learning Feedforward Neural Network* (FFNN) Layer Output

Prediktor		Output Layer Pertamax_In	Prediktor	Output Layer Pertamax_In	Prediktor	Output Layer Pertamax_In
Hidden Layer 2	(Bias)	0,042	H(2:11)	0,179	H(2:21)	0,231
	H(2:1)	-0,409	H(2:12)	0,169	H(2:22)	-0,011
	H(2:2)	-0,122	H(2:13)	0,098	H(2:23)	0,286
	H(2:3)	-0,375	H(2:14)	0,154	H(2:24)	0,023
	H(2:4)	0,299	H(2:15)	-0,039	H(2:25)	0,274
	H(2:5)	0,181	H(2:16)	0,213	H(2:26)	-0,452
	H(2:6)	-0,263	H(2:17)	0,031	H(2:27)	-0,327
	H(2:7)	-0,050	H(2:18)	0,342	H(2:28)	-0,470
	H(2:8)	-0,256	H(2:19)	0,437	H(2:29)	-0,013
	H(2:9)	0,450	H(2:20)	0,399	H(2:30)	-0,459
	H(2:10)	0,421				

Tabel 4.17 menunjukkan bahwa *neuron* pada 2 *hidden layer* masing-masing 25 dan 30 dengan fungsi aktivasi sigmoid untuk *layer output*, maka persamaan matematis yang didapatkan adalah sebagai berikut:

*Layer Output* :

$$\begin{aligned}\hat{Z}_t = & b^o + w_1^o f_1^{h_2} + w_2^o f_2^{h_2} + w_3^o f_3^{h_2} + w_4^o f_4^{h_2} + w_5^o f_5^{h_2} + w_6^o f_6^{h_2} + w_7^o f_7^{h_2} + w_8^o f_8^{h_2} \\ & + w_9^o f_9^{h_2} + w_{10}^o f_{10}^{h_2} + w_{11}^o f_{11}^{h_2} + w_{12}^o f_{12}^{h_2} + w_{13}^o f_{13}^{h_2} + w_{14}^o f_{14}^{h_2} + w_{15}^o f_{15}^{h_2} \\ & + w_{16}^o f_{16}^{h_2} + w_{17}^o f_{17}^{h_2} + w_{18}^o f_{18}^{h_2} + w_{19}^o f_{19}^{h_2} + w_{20}^o f_{20}^{h_2} + w_{21}^o f_{21}^{h_2} + w_{22}^o f_{22}^{h_2} \\ & + w_{23}^o f_{23}^{h_2} + w_{24}^o f_{24}^{h_2} + w_{25}^o f_{25}^{h_2} + w_{26}^o f_{26}^{h_2} + w_{27}^o f_{27}^{h_2} + w_{28}^o f_{28}^{h_2} + w_{29}^o f_{29}^{h_2} \\ & + w_{30}^o f_{30}^{h_2}\end{aligned}$$

atau :

$$\begin{aligned}\hat{Z}_t = & 0,042 - 0,409f_1^{h_2} - 0,122f_2^{h_2} - 0,375f_3^{h_2} + 0,299f_4^{h_2} + 0,181f_5^{h_2} - \\ & 0,263f_6^{h_2} - 0,050f_7^{h_2} - 0,256f_8^{h_2} + 0,450f_9^{h_2} + 0,421f_{10}^{h_2} + 0,179 f_{11}^{h_2} \\ & + 0,169f_{12}^{h_2} + 0,098f_{13}^{h_2} + 0,154f_{14}^{h_2} - 0,039f_{15}^{h_2} + 0,213f_{16}^{h_2} + \\ & 0,031f_{17}^{h_2} + 0,342f_{18}^{h_2} + 0,437f_{19}^{h_2} + 0,399f_{20}^{h_2} + 0,231f_{21}^{h_2} - 0,011f_{22}^{h_2} \\ & + 0,286f_{23}^{h_2} + 0,023f_{24}^{h_2} + 0,274f_{25}^{h_2} - 0,452f_{26}^{h_2} - 0,327f_{27}^{h_2} \\ & - 0,470f_{28}^{h_2} - 0,013f_{29}^{h_2} - 0,459f_{30}^{h_2}\end{aligned}$$

Pada model-model *Feedforward Neural Network* (FFNN) untuk *layer output* dapat dijelaskan bahwa apabila bobot *hidden layer* 2 pada *neuron* 1 naik sebesar satu satuan, maka volume penjualan pertamax akan turun sebesar 0,409 satuan dengan asumsi *neuron* lainnya konstan, dan seterusnya. Tabel 4.18 akan ditampilkan *neuron* pada 2 *hidden layer* masing-masing 25 dan 30 dengan fungsi aktivasi sigmoid untuk *layer* tersembunyi kedua, persamaan matematis yang didapatkan adalah sebagai berikut:

**Tabel 4.18** Estimasi Parameter *Learning Feedforward Neural Network* (FFNN) *Layer* Tersembunyi Kedua

Prediktor		<i>Hidden Layer 2</i>							
		H(2:1)	H(2:2)	H(2:3)	H(2:4)	H(2:5)	H(2:6)	H(2:7)	H(2:8)
<i>Hidden Layer 1</i>	(Bias)	0,324	-0,466	-0,170	0,272	-0,012	0,408	0,028	0,187
	H(1:1)	-0,337	-0,007	-0,394	-0,410	0,310	0,434	-0,025	-0,383
	H(1:2)	0,345	-0,317	-0,419	0,222	-0,038	0,042	0,079	-0,137
	H(1:3)	0,283	-0,391	0,009	0,160	-0,177	-0,252	-0,300	-0,479
	H(1:4)	0,143	-0,113	-0,013	-0,141	0,234	0,458	-0,130	0,432
	H(1:5)	-0,351	0,158	-0,450	0,398	0,341	-0,208	0,086	0,053
	H(1:6)	0,381	-0,352	0,465	-0,349	-0,198	0,256	0,151	-0,152
	H(1:7)	-0,146	-0,005	-0,127	0,289	0,499	-0,373	-0,375	-0,272



**Tabel 4.19** Estimasi Parameter *Learning Feedforward Neural Network* (FFNN) Layer Tersembunyi Kedua Untuk (Lanjutan 1)

Prediktor		<i>Hidden Layer 2</i>							
		H(2:1)	H(2:2)	H(2:3)	H(2:4)	H(2:5)	H(2:6)	H(2:7)	H(2:8)
<i>Hidden Layer 1</i>	(Bias)	0,324	-0,466	-0,170	0,272	-0,012	0,408	0,028	0,187
	H(1:1)	-0,337	-0,007	-0,394	-0,410	0,310	0,434	-0,025	-0,383
	H(1:2)	0,345	-0,317	-0,419	0,222	-0,038	0,042	0,079	-0,137
	H(1:3)	0,283	-0,391	0,009	0,160	-0,177	-0,252	-0,300	-0,479
	H(1:4)	0,143	-0,113	-0,013	-0,141	0,234	0,458	-0,130	0,432
	H(1:5)	-0,351	0,158	-0,450	0,398	0,341	-0,208	0,086	0,053
	H(1:6)	0,381	-0,352	0,465	-0,349	-0,198	0,256	0,151	-0,152
	H(1:7)	-0,146	-0,005	-0,127	0,289	0,499	-0,373	-0,375	-0,272
	H(1:8)	0,026	0,237	-0,375	-0,331	0,333	-0,312	0,020	0,178
	H(1:9)	0,230	0,475	0,158	0,036	0,315	0,359	-0,473	-0,214
	H(1:10)	-0,075	0,105	-0,227	0,407	0,210	0,064	0,475	0,435
	H(1:11)	0,121	-0,422	0,486	0,047	-0,265	-0,168	0,235	0,410
	H(1:12)	-0,031	-0,282	0,296	0,419	0,427	-0,004	-0,018	-0,033
	H(1:13)	-0,413	-0,121	-0,215	0,461	0,291	0,481	-0,398	0,181
	H(1:14)	-0,129	0,345	0,099	0,142	0,476	-0,281	-0,098	-0,382
	H(1:15)	-0,163	-0,227	-0,309	0,033	0,051	0,111	-0,382	-0,127
	H(1:16)	0,487	0,335	-0,041	0,433	0,113	-0,399	-0,316	-0,163
	H(1:17)	0,039	0,072	-0,065	-0,285	0,225	0,192	0,428	-0,148
	H(1:18)	-0,207	-0,312	-0,383	0,075	0,011	0,334	-0,299	-0,136
	H(1:19)	-0,337	0,154	0,044	-0,097	0,378	0,477	0,381	-0,464
	H(1:20)	0,410	0,357	0,201	-0,114	-0,170	-0,145	-0,456	0,001
	H(1:21)	-0,052	-0,401	-0,140	-0,077	0,378	0,150	-0,386	-0,351
	H(1:22)	-0,424	0,490	-0,243	0,002	-0,445	0,120	-0,298	-0,457
	H(1:23)	0,462	0,072	0,167	-0,413	-0,340	0,084	0,397	0,173
	H(1:24)	0,461	-0,426	-0,207	0,378	-0,309	0,86	0,072	-0,427
	H(1:25)	-0,447	0,480	-0,460	0,083	-0,085	0,155	0,225	0,138
Prediktor		<i>Hidden Layer 2</i>							
		H(2:9)	H(2:10)	H(2:11)	H(2:12)	H(2:13)	H(2:14)	H(2:15)	H(2:16)
<i>Hidden Layer 1</i>	(Bias)	0,172	-0,300	-0,292	0,373	-0,264	-0,383	-0,018	0,140
	H(1:1)	-0,284	-0,359	0,018	0,074	-0,334	0,207	0,463	0,070
	H(1:2)	-0,496	-0,085	0,104	-0,147	0,135	-0,187	0,478	-0,265
	H(1:3)	-0,311	-0,203	0,217	0,040	-0,335	-0,489	-0,061	-0,168
	H(1:4)	0,471	-0,397	-0,333	-0,451	-0,007	-0,176	-0,231	0,009
	H(1:5)	-0,421	0,007	0,248	0,039	0,406	-0,265	-0,220	0,089
	H(1:6)	0,443	0,330	0,029	-0,457	0,299	0,413	0,235	0,309
	H(1:7)	-0,033	0,020	-0,427	-0,258	0,334	-0,339	0,435	0,441
	H(1:8)	0,129	-0,031	0,380	-0,273	-0,329	0,248	-0,491	-0,012
	H(1:9)	-0,192	0,324	-0,091	-0,145	-0,214	-0,339	0,152	0,184
	H(1:10)	-0,010	0,367	-0,181	0,239	-0,450	0,248	0,331	-0,437
	H(1:11)	0,089	-0,402	-0,093	0,376	-0,374	-0,339	0,304	0,320
	H(1:12)	-0,161	0,052	0,489	-0,428	-0,078	0,147	-0,037	-0,279
	H(1:13)	-0,282	0,086	-0,418	0,416	0,111	-0,028	0,338	-0,377
	H(1:14)	-0,407	-0,396	-0,280	-0,087	-0,239	0,039	-0,154	0,471
	H(1:15)	-0,061	0,173	-0,073	0,223	0,189	0,021	0,017	0,212
	H(1:16)	-0,324	0,025	-0,373	-0,120	-0,062	-0,173	0,203	-0,262
	H(1:17)	-0,465	0,063	0,132	-0,261	-0,306	0,183	0,370	-0,147
	H(1:18)	0,010	0,167	-0,334	-0,374	0,224	0,020	0,258	-0,494
	H(1:19)	0,269	-0,400	-0,224	-0,294	-0,479	-0,185	0,157	0,186
	H(1:20)	0,076	-0,239	0,095	0,065	0,466	-0,492	-0,061	-0,055
	H(1:21)	0,125	0,133	-0,412	0,428	-0,106	0,019	-0,015	0,030
	H(1:22)	-0,192	0,138	0,239	0,343	-0,190	-0,183	-0,392	-0,077
	H(1:23)	-0,076	0,286	-0,235	-0,075	0,130	0,093	0,175	0,252

**Tabel 4.20** Estimasi Parameter *Learning Feedforward Neural Network* (FFNN) Layer Tersembunyi Kedua (Lanjutan 2)

	H(1:24)	0,435	0,261	0,309	0,227	-0,014	0,288	0,189	-0,337
	H(1:25)	0,217	-0,163	-0,318	-0,266	-0,251	-0,075	-0,259	0,143
Prediktor		<i>Hidden Layer 2</i>							
		H(2:17)	H(2:18)	H(2:19)	H(2:20)	H(2:21)	H(2:22)	H(2:23)	H(2:24)
<i>Hidden Layer 1</i>	(Bias)	0,336	0,098	0,424	-0,037	-0,449	-0,399	-0,117	-0,263
	H(1:1)	0,063	-0,274	-0,097	0,191	-0,421	-0,313	0,034	-0,167
	H(1:2)	0,390	-0,190	-0,310	-0,496	-0,016	-0,388	-0,343	0,029
	H(1:3)	-0,401	-0,076	0,268	-0,175	0,105	0,463	-0,233	-0,367
	H(1:4)	0,315	0,229	0,211	-0,262	0,412	0,164	-0,449	0,314
	H(1:5)	0,156	0,171	-0,205	0,318	0,380	0,481	0,322	0,208
	H(1:6)	-0,221	0,472	0,147	0,447	0,360	0,491	-0,324	0,176
	H(1:7)	0,221	-0,357	0,242	0,314	0,397	0,167	0,203	0,456
	H(1:8)	0,034	0,116	0,113	-0,286	-0,435	0,323	0,337	0,159
	H(1:9)	0,381	0,170	0,331	0,232	-0,301	0,347	-0,150	-0,109
	H(1:10)	0,299	0,181	0,271	0,114	-0,392	-0,092	-0,373	0,116
	H(1:11)	-0,013	0,168	0,381	-0,485	0,414	0,146	0,041	0,434
	H(1:12)	0,464	-0,277	0,201	-0,144	-0,081	0,072	-0,117	-0,466
	H(1:13)	0,265	0,002	-0,100	-0,033	-0,264	-0,432	-0,238	-0,357
	H(1:14)	0,044	0,343	0,489	-0,121	0,444	-0,172	0,476	0,436
	H(1:15)	-0,137	-0,070	-0,239	0,223	-0,491	0,436	-0,237	-0,304
	H(1:16)	-0,267	-0,395	0,219	0,298	-0,234	0,342	-0,369	0,284
	H(1:17)	0,250	-0,454	0,323	-0,322	-0,263	-0,219	-0,003	0,499
	H(1:18)	0,147	-0,063	0,212	-0,292	0,326	-0,420	-0,118	-0,438
	H(1:19)	0,331	-0,357	0,374	-0,393	0,096	0,006	-0,459	-0,250
	H(1:20)	0,416	-0,272	0,095	-0,390	0,191	-0,002	0,331	-0,152
	H(1:21)	-0,241	0,478	0,390	0,056	0,012	0,073	0,275	0,183
	H(1:22)	0,287	0,403	-0,293	-0,121	0,229	-0,396	0,255	0,479
	H(1:23)	-0,276	0,122	-0,074	0,326	0,263	0,486	-0,454	0,423
	H(1:24)	-0,273	-0,396	-0,194	0,179	-0,247	-0,114	-0,086	0,108
	H(1:25)	0,009	-0,019	-0,039	-0,438	0,352	0,003	0,212	-0,132
Prediktor		<i>Hidden Layer 2</i>							
		H(2:25)	H(2:26)	H(2:27)	H(2:28)		H(2:29)		H(2:30)
<i>Hidden Layer 1</i>	(Bias)	0,253	-0,204	-0,351	-0,288		0,450		-0,475
	H(1:1)	-0,369	0,202	0,360	-0,101		-0,457		0,320
	H(1:2)	-0,482	0,320	0,092	0,009		-0,323		-0,347
	H(1:3)	-0,207	0,076	-0,215	-0,096		-0,228		0,081
	H(1:4)	-0,355	0,484	-0,134	-0,221		-0,371		0,394
	H(1:5)	0,403	-0,034	-0,285	-0,387		0,385		-0,298
	H(1:6)	0,021	0,163	0,397	0,437		-0,266		0,080
	H(1:7)	-0,081	0,030	0,063	0,292		0,228		0,205
	H(1:8)	0,182	-0,327	-0,041	-0,248		-0,151		-0,035
	H(1:9)	0,182	0,219	0,438	0,058		0,282		-0,251
	H(1:10)	-0,013	0,207	-0,127	-0,372		0,371		-0,182
	H(1:11)	-0,268	-0,326	-0,245	-0,178		0,062		-0,333
	H(1:12)	0,418	0,379	0,492	-0,239		0,163		-0,033
	H(1:13)	-0,019	0,467	-0,118	-0,443		0,177		-0,224
	H(1:14)	0,080	0,264	-0,201	0,276		-0,408		-0,298
	H(1:15)	-0,359	0,036	0,308	0,262		-0,206		0,339
	H(1:16)	0,328	-0,473	0,291	0,178		-0,242		0,248
	H(1:17)	-0,248	0,213	-0,063	-0,056		0,337		0,187
	H(1:18)	0,035	-0,413	-0,184	-0,141		0,161		0,030
	H(1:19)	0,133	-0,033	0,244	-0,432		-0,256		0,072
	H(1:20)	0,051	0,309	-0,208	0,007		0,368		-0,164
	H(1:21)	-0,430	-0,102	-0,484	0,214		-0,453		-0,007

**Tabel 4.21** Estimasi Parameter *Learning Feedforward Neural Network* (FFNN) *Layer* Tersembunyi Kedua Untuk *Layer* Tersembunyi Kedua (Lanjutan 3)

Prediktor		<i>Hidden Layer 2</i>					
		H(2:25)	H(2:26)	H(2:27)	H(2:28)	H(2:29)	H(2:30)
<i>Hidden Layer 1</i>	H(1:22)	-0,380	0,423	0,401	0,355	-0,080	-0,172
	H(1:23)	-0,105	0,078	0,015	0,346	0,448	-0,307
	H(1:24)	0,002	0,289	0,413	0,024	0,023	0,189
	H(1:25)	0,103	-01,42	-0,378	-0,261	-0,495	-0,414

*Layer* tersembunyi kedua:

$$\begin{aligned}
 f_1^{h_2} = & b_1^{h_2} + w_1^{h_1} f_1^{h_1} + w_2^{h_1} f_2^{h_1} + w_3^{h_1} f_3^{h_1} + w_4^{h_1} f_4^{h_1} + w_5^{h_1} f_5^{h_1} + w_6^{h_1} f_6^{h_1} + w_7^{h_1} f_7^{h_1} \\
 & + w_8^{h_1} f_8^{h_1} + w_9^{h_1} f_9^{h_1} + w_{10}^{h_1} f_{10}^{h_1} + w_{11}^{h_1} f_{11}^{h_1} + w_{12}^{h_1} f_{12}^{h_1} + w_{13}^{h_1} f_{13}^{h_1} + w_{14}^{h_1} f_{14}^{h_1} \\
 & + w_{15}^{h_1} f_{15}^{h_1} + w_{16}^{h_1} f_{16}^{h_1} + w_{17}^{h_1} f_{17}^{h_1} + w_{18}^{h_1} f_{18}^{h_1} + w_{19}^{h_1} f_{19}^{h_1} + w_{20}^{h_1} f_{20}^{h_1} + w_{21}^{h_1} f_{21}^{h_1} \\
 & + w_{22}^{h_1} f_{22}^{h_1} + w_{23}^{h_1} f_{23}^{h_1} + w_{24}^{h_1} f_{24}^{h_1} + w_{25}^{h_1} f_{25}^{h_1}
 \end{aligned}$$

$$\begin{aligned}
 = & 0,324 + 0,337f_1^{h_1} + 0,345f_2^{h_1} + 0,283f_3^{h_1} + 0,143f_4^{h_1} - 0,351f_5^{h_1} + \\
 & 0,381f_6^{h_1} - 0,146f_7^{h_1} + 0,026f_8^{h_1} + 0,230f_9^{h_1} - 0,075f_{10}^{h_1} + 0,121f_{11}^{h_1} - \\
 & 0,031f_{12}^{h_1} - 0,413f_{13}^{h_1} - 0,129f_{14}^{h_1} - 0,163f_{15}^{h_1} + 0,487f_{16}^{h_1} + \\
 & 0,039f_{17}^{h_1} - 0,207f_{18}^{h_1} - 0,337f_{19}^{h_1} + 0,410f_{20}^{h_1} - 0,052f_{21}^{h_1} - \\
 & 0,424f_{22}^{h_1} + 0,462f_{23}^{h_1} + 0,461f_{24}^{h_1} - 0,447f_{25}^{h_1}
 \end{aligned}$$

$$\begin{aligned}
 f_2^{h_2} = & -0,466 - 0,007f_1^{h_1} - 0,317f_2^{h_1} - 0,391f_3^{h_1} - 0,113f_4^{h_1} + 0,158f_5^{h_1} \\
 & - 0,352f_6^{h_1} - 0,005f_7^{h_1} + 0,237f_8^{h_1} + 0,475f_9^{h_1} + 0,105f_{10}^{h_1} - 0,422f_{11}^{h_1} - \\
 & 0,282f_{12}^{h_1} - 0,121f_{13}^{h_1} + 0,345f_{14}^{h_1} - 0,277f_{15}^{h_1} + 0,335f_{16}^{h_1} + \\
 & 0,072f_{17}^{h_1} - 0,312f_{18}^{h_1} + 0,154f_{19}^{h_1} + 0,357f_{20}^{h_1} - 0,401f_{21}^{h_1} + \\
 & 0,490f_{22}^{h_1} + 0,072f_{23}^{h_1} - 0,426f_{24}^{h_1} + 0,480f_{25}^{h_1}
 \end{aligned}$$

⋮

$$\begin{aligned}
 f_{29}^{h_2} = & -0,450 - 0,457f_1^{h_1} - 0,323f_2^{h_1} - 0,228f_3^{h_1} - 0,371f_4^{h_1} + 0,385f_5^{h_1} \\
 & - 0,266f_6^{h_1} + 0,228f_7^{h_1} - 0,151f_8^{h_1} + 0,282f_9^{h_1} + 0,371f_{10}^{h_1} + 0,062f_{11}^{h_1} \\
 & + 0,168f_{12}^{h_1} + 0,177f_{13}^{h_1} - 0,408f_{14}^{h_1} - 0,206f_{15}^{h_1} - 0,242f_{16}^{h_1} + \\
 & 0,337f_{17}^{h_1} + 0,161f_{18}^{h_1} - 0,256f_{19}^{h_1} + 0,368f_{20}^{h_1} - 0,453f_{21}^{h_1} \\
 & - 0,080f_{22}^{h_1} + 0,448f_{23}^{h_1} + 0,023f_{24}^{h_1} - 0,495f_{25}^{h_1}
 \end{aligned}$$

$$f_{30}^{h_2} = -0,475 + 0,320f_1^{h_1} - 0,347f_2^{h_1} + 0,081f_3^{h_1} + 0,394f_4^{h_1} - 0,298f_5^{h_1} + 0,080f_6^{h_1} + 0,205f_7^{h_1} - 0,035f_8^{h_1} - 0,251f_9^{h_1} - 0,182f_{10}^{h_1} - 0,333f_{11}^{h_1} - 0,033f_{12}^{h_1} - 0,224f_{13}^{h_1} - 0,298f_{14}^{h_1} + 0,339f_{15}^{h_1} + 0,248f_{16}^{h_1} + 0,187f_{17}^{h_1} + 0,030f_{18}^{h_1} + 0,072f_{19}^{h_1} - 0,164f_{20}^{h_1} - 0,007f_{21}^{h_1} - 0,172f_{22}^{h_1} - 0,370f_{23}^{h_1} + 0,189f_{24}^{h_1} - 0,414f_{25}^{h_1}$$

Terkait model-model untuk *layer* tersembunyi kedua dapat dijelaskan bahwa apabila bobot *hidden layer* 1 pada *neuron* 1 naik sebesar satu satuan, maka bobot *layer* tersembunyi kedua pada *neuron* 1 akan turun sebesar 0,337 satuan dengan asumsi *neuron* lainnya konstan, dan seterusnya. Pada Tabel 4.21 akan ditampilkan *neuron* pada 2 *hidden layer* masing-masing 25 dan 30 dengan fungsi aktivasi sigmoid untuk *layer* tersembunyi kesatu, persamaan matematis yang didapatkan adalah sebagai berikut:

**Tabel 4.22** Estimasi Parameter *Learning Feedforward Neural Network* (FFNN)  
Untuk *Layer* Tersembunyi Kesatu

Prediktor		<i>Hidden Layer 1</i>				
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)
<i>Input Layer</i>	(Bias)	0,071	-0,438	-0,382	0,225	-0,407
	PACF	-0,200	0,016	0,136	0,068	0,298
Prediktor		<i>Hidden Layer 1</i>				
		H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)
<i>Input Layer</i>	(Bias)	-0,419	0,287	-0,454	0,104	-0,442
	PACF	0,259	0,432	0,007	0,441	-0,190
Prediktor		<i>Hidden Layer 1</i>				
		H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)
<i>Input Layer</i>	(Bias)	0,410	-0,408	0,245	-0,072	0,399
	PACF	-0,127	-0,062	-0,020	0,182	-0,129
Prediktor		<i>Hidden Layer 1</i>				
		H(1:16)	H(1:17)	H(1:18)	H(1:19)	H(1:20)
<i>Input Layer</i>	(Bias)	-0,144	0,066	-0,488	-0,373	0,244
	PACF	0,352	0,013	0,124	0,045	-0,341
Prediktor		<i>Hidden Layer 1</i>				
		H(1:21)	H(1:22)	H(1:23)	H(1:24)	H(1:25)
<i>Input Layer</i>	(Bias)	-0,426	-0,118	-0,283	-0,498	0,405
	PACF	0,439	0,232	-0,411	0,495	-0,012

*Layer* tersembunyi kesatu:

$$f_1^{h_1} = f(b_1 + w_1 Y_{t-1}) = 0,071 - 0,200 Y_{t-1}$$

$$f_2^{h_1} = f(b_2 + w_2 Y_{t-1}) = -0,438 + 0,016 Y_{t-1}$$

$$\begin{aligned}
& \vdots \\
f_{24}^{h_1} &= f(b_{24} + w_{24}Y_{t-1}) = -0,498 + 0,495 Y_{t-1} \\
f_{25}^{h_1} &= f(b_{25} + w_{25}Y_{t-1}) = 0,405 - 0,012 Y_{t-1} \\
& \text{dimana:} \\
f(b_1 + w_1Y_{t-1}) &= \frac{1}{1+e^{-(b_1+w_1Y_{t-1})}} = \frac{1}{1+e^{-(0,071 - 0,200Y_{t-1})}} \\
f(b_2 + w_2Y_{t-1}) &= \frac{1}{1+e^{-(b_2+w_2Y_{t-1})}} = \frac{1}{1+e^{-(0,438 + 0,016Y_{t-1})}} \\
& \vdots \\
f(b_{24} + w_{24}Y_{t-1}) &= \frac{1}{1+e^{-(b_{24}+w_{24}Y_{t-1})}} = \frac{1}{1+e^{-(0,498 + 0,495Y_{t-1})}} \\
f(b_{25} + w_{25}Y_{t-1}) &= \frac{1}{1+e^{-(b_{25}+w_{25}Y_{t-1})}} = \frac{1}{1+e^{-(0,405 - 0,012Y_{t-1})}}
\end{aligned}$$

Terkait model-model untuk *layer* tersembunyi kesatu dapat dijelaskan bahwa apabila bobot lag PACF naik sebesar satu satuan, maka bobot *layer* tersembunyi kesatu pada *neuron* 1 akan turun sebesar 0,200 satuan dengan asumsi *neuron* lainnya konstan, dan seterusnya.

#### 4.4 Pemodelan Penjualan Pertamina dengan Metode *Hybrid* ARIMAX-*Feedforward Neural Network* (FFNN)

Metode *hybrid* ini menggabungkan dua model yaitu model linear berupa ARIMAX dan model non-linear yaitu pemodelan residual ARIMAX dengan metode *Neural Network*. Residual yang dimodelkan dengan *Neural Network* merupakan model ARIMAX(1,1,0). Pemodelan residual dengan FFNN digunakan input berdasarkan lag pada PACF. Berikut ini adalah nilai kriteria model terbaik metode *hybrid* ARIMAX-FFNN dapat dilihat pada Tabel 4.23 dan Tabel 4.24 sebagai berikut:


**Tabel 4.23** Kriteria Model Terbaik Metode *Hybrid* ARIMAX-FFNN

Model <i>Hybrid</i> ARIMAX-FFNN	Jumlah <i>Neuron</i>	Nilai <i>Error</i>	
		RMSE-in	RMSEP
1 <i>Hidden Layer</i>	1	472,4684	556,0833
	3	479,1646	575,3333
	5	481,8734	558,9167
	6	468,3038	557
	9	473,5696	519,8333

**Tabel 4.24** Kriteria Model Terbaik Metode *Hybrid* ARIMAX-FFNN (Lanjutan)

	Jumlah Neuron	Nilai Error	
		RMSE-in	RMSEP
1 Hidden Layer	10	474,0633	557,1667
	14	493,3038	538,0833
	15	478,1266	513,0833
	17	475,962	501
	19	476,6582	<b>500,5</b>
	20	473,0127	543,1667
	22	477,2405	507
	25	471,9873	548,75
	27	477,4177	514,25
	29	473,5443	559,0833
	30	474,6962	536,25
2 Hidden Layer	1-3	473,7215	550,0833
	2-6	478,2405	587,5833
	5-2	477,3544	565,25
	7-10	478,0506	578,0833
	6-8	480,0886	552
	9-13	482,1519	591,5833
	14-11	479,3038	585,75
	18-22	478,8481	584
	16-14	479,1392	585,25
	20-25	478,7215	587,25
	27-23	483,1899	549,25
	25-30	504,7342	534,0833
	30-30	478,0759	585,6667

Tabel 4.23 dan Tabel 4.24 menunjukkan bahwa 1 *hidden layer* dan jumlah *neuron* sebanyak 19 mempunyai nilai *error* minimum yaitu 500,5. Berikut ini arsitektur model *hybrid* untuk FFNN (1-19-1):



**Gambar 4.10** Arsitektur *Hybrid* ARIMAX-FFNN(1-19-1)

Secara umum arsitektur jaringan model *Hybrid* ARIMAX-FFNN dapat dimodelkan sesuai dengan fungsi aktivasi sigmoid pada *hidden layer* dan fungsi linear pada *output*. Hasil estimasi *Hybrid* untuk *learning Feedforward Neural Network* (FFNN) sebagai berikut:

**Tabel 4.25** Estimasi Parameter *Hybrid Learning Feedforward Neural Network* (FFNN)

Layer Output				
Prediktor		Output Layer Pertamax_In	Prediktor	Output Layer Pertamax_In
Hidden Layer 1	(Bias)	0,257	H(1:10)	-0,482
	H(1:1)	-0,188	H(1:11)	0,344
	H(1:2)	0,981	H(1:12)	-0,686
	H(1:3)	-0,201	H(1:13)	0,436
	H(1:4)	0,294	H(1:14)	0,547
	H(1:5)	-0,442	H(1:15)	-0,143
	H(1:6)	-0,129	H(1:16)	0,049
	H(1:7)	-0,120	H(1:17)	-0,065
	H(1:8)	0,591	H(1:18)	-0,112
	H(1:9)	-0,153	H(1:19)	-0,415

Tabel 4.25 menunjukkan bahwa pada 1 *hidden layer* dengan 19 *neuron* dengan fungsi aktivasi sigmoid, maka persamaan matematis *layer output* untuk mendapatkan nilai peramalan dari metode *Hybrid* untuk *Neural Network* adalah sebagai berikut:

*Layer Output :*

$$\begin{aligned}\hat{N}_t = & b^o + w_1^o f_1^{h_1} + w_2^o f_2^{h_1} + w_3^o f_3^{h_1} + w_4^o f_4^{h_1} + w_5^o f_5^{h_1} + w_6^o f_6^{h_1} + w_7^o f_7^{h_1} + w_8^o f_8^{h_1} \\ & + w_9^o f_9^{h_1} + w_{10}^o f_{10}^{h_1} + w_{11}^o f_{11}^{h_1} + w_{12}^o f_{12}^{h_1} + w_{13}^o f_{13}^{h_1} + w_{14}^o f_{14}^{h_1} + w_{15}^o f_{15}^{h_1} \\ & + w_{16}^o f_{16}^{h_1} + w_{17}^o f_{17}^{h_1} + w_{18}^o f_{18}^{h_1} + w_{19}^o f_{19}^{h_1}\end{aligned}$$

$$\begin{aligned}\hat{N}_t = & 0,257 - 0,188f_1^{h_1} + 0,981f_2^{h_1} - 0,201f_3^{h_1} + 0,294f_4^{h_1} - 0,442f_5^{h_1} \\ & - 0,129f_6^{h_1} - 0,120f_7^{h_1} + 0,591f_8^{h_1} - 0,153f_9^{h_1} - 0,482f_{10}^{h_1} + \\ & 0,344f_{11}^{h_1} - 0,686f_{12}^{h_1} + 0,436f_{13}^{h_1} + 0,547f_{14}^{h_1} - 0,143f_{15}^{h_1} + \\ & 0,049f_{16}^{h_1} - 0,065f_{17}^{h_1} - 0,112f_{18}^{h_1} - 0,415f_{19}^{h_1}\end{aligned}$$

Terkait model-model *Hybrid* ARIMAX-FFNN dapat dijelaskan bahwa apabila bobot *hidden layer* 1 pada *neuron* 1 naik sebesar satu satuan, maka penjualan pertamax akan turun sebesar 0,188 satuan dengan asumsi *neuron* lainnya konstan, dan seterusnya. Tabel 4.25 menunjukkan bahwa estimasi pada 1

*hidden layer* dengan 19 *neuron* dengan fungsi aktivasi sigmoid, maka persamaan matematis *layer* tersembunyi kesatu untuk mendapatkan nilai peramalan dari metode *Hybrid* untuk *neural network* adalah sebagai berikut:

**Tabel 4.26** Estimasi Parameter *Hybrid Learning Feedforward Neural Network* (FFNN)  
Untuk *Layer* Tersembunyi Kesatu

Prediktor		<i>Hidden Layer 1</i>				
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)
<i>Input Layer</i>	(Bias)	-0,164	-0,759	0,438	-0,483	0,493
	Input NN	-0,316	-1,767	-0,257	-0,420	0,999
Prediktor		<i>Hidden Layer 1</i>				
		H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)
<i>Input Layer</i>	(Bias)	0,643	0,340	0,196	-0,025	0,243
	Input NN	0,970	-0,235	0,134	-0,010	-0,672
Prediktor		<i>Hidden Layer 1</i>				
		H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)
<i>Input Layer</i>	(Bias)	-0,070	0,660	-0,285	0,063	-0,186
	Input NN	0,279	-0,496	-0,423	0,455	-0,131
Prediktor		<i>Hidden Layer 1</i>				
		H(1:16)	H(1:17)	H(1:18)	H(1:19)	
<i>Input Layer</i>	(Bias)	-0,166	-0,205	0,009	0,455	
	Input NN	-0,082	-0,261	-0,156	0,463	

*Layer* tersembunyi kesatu :

$$f_1^{h_1} = f(b_1 + w_1 e_{t-1}) = -0,164 - 0,316 e_{t-1}$$

$$f_2^{h_1} = f(b_2 + w_2 e_{t-1}) = -0,759 - 1,767 e_{t-1}$$

⋮

$$f_{18}^{h_1} = f(b_{18} + w_{18} e_{t-1}) = 0,009 - 0,156 e_{t-1}$$

$$f_{19}^{h_1} = f(b_{19} + w_{19} e_{t-1}) = 0,455 - 0,463 e_{t-1}$$

dimana:

$$f(b_1 + w_1 e_{t-1}) = \frac{1}{1 + e^{-(b_1 + w_1 e_{t-1})}} = \frac{1}{1 + e^{-(-0,164 - 0,316 e_{t-1})}}$$

$$f(b_2 + w_2 e_{t-1}) = \frac{1}{1 + e^{-(b_2 + w_2 e_{t-1})}} = \frac{1}{1 + e^{-(-0,759 - 1,767 e_{t-1})}}$$

⋮

$$f(b_{18} + w_{18} e_{t-1}) = \frac{1}{1 + e^{-(b_{18} + w_{18} e_{t-1})}} = \frac{1}{1 + e^{-(0,009 - 0,156 e_{t-1})}}$$

$$f(b_{19} + w_{19} e_{t-1}) = \frac{1}{1 + e^{-(b_{19} + w_{19} e_{t-1})}} = \frac{1}{1 + e^{-(0,455 - 0,463 e_{t-1})}}$$



Terkait model-model *Hybrid learning Feedforward Neural Network* (FFNN) dapat dijelaskan bahwa apabila bobot residual naik sebesar satu satuan, maka penjualan bobot *layer* tersembunyi kesatu akan turun sebesar 0,316 satuan dengan asumsi variabel lainnya konstan, dan seterusnya.

Secara umum kombinasi dari model *time series Hybrid* adalah  $Y_t = L_t + N_t$ , dimana  $L_t$  merupakan komponen linear berupa hasil peramalan ARIMAX (1,1,0) dari data penjualan pertamax dan  $N_t$  merupakan komponen non-linear berupa hasil peramalan FFNN. Jadi, pemodelan *Hybrid* ARIMAX-FFNN yang terbentuk adalah sebagai berikut:

$$\begin{aligned}\hat{Z}_t &= \hat{L}_t + \hat{N}_t \\ &= 0,44056\hat{Z}_{t-1} + 0,32313 X_{1,t} - 1648,4 X_{2,t} + 771,75284 I_{S,t}^{61} - 1365,3 I_{A,t}^{66} \\ &\quad + 653,44574 I_{S,t}^{72} + 913,35894 I_{S,t}^{73} + \frac{1}{(1-B)} a_t + 0,257 - 0,188 f_1^{h_1} + \\ &\quad 0,981 f_2^{h_1} - 0,201 f_3^{h_1} + 0,294 f_4^{h_1} - 0,442 f_5^{h_1} - 0,129 f_6^{h_1} - 0,120 f_7^{h_1} + \\ &\quad 0,591 f_8^{h_1} - 0,153 f_9^{h_1} - 0,482 f_{10}^{h_1} + 0,344 f_{11}^{h_1} - 0,686 f_{12}^{h_1} + 0,436 f_{13}^{h_1} \\ &\quad + 0,547 f_{14}^{h_1} - 0,143 f_{15}^{h_1} + 0,049 f_{16}^{h_1} - 0,065 f_{17}^{h_1} - 0,112 f_{18}^{h_1} - \\ &\quad 0,415 f_{19}^{h_1}\end{aligned}$$

Terkait model *Hybrid* FFNN-ARIMAX dapat dijelaskan bahwa apabila voume penjualan pertalite naik sebesar satu satuan, maka penjualan pertamax akan turun sebesar 1648,4 kl dengan asumsi variabel lainnya konstan, dan seterusnya.


#### 4.5 Perbandingan Pemilihan Model Terbaik Data Penjualan Pertamax dengan Metode ARIMAX, FFNN, dan *Hybrid* ARIMAX-FFNN

Perbandingan ketiga model peramalan yaitu ARIMAX (1,1,0), FFNN (1-25-30-1), dan *Hybrid* ARIMAX-FFNN dengan model NN residual (1-19-1) dapat ditunjukkan dengan nilai RMSE sebagai berikut:

**Tabel 4.27** Perbandingan Nilai RMSE Ketiga Metode

Model	RMSE- <i>in</i>	RMSEP
ARIMAX	368,273	1411
FFNN	611	<b>214,917</b>
<i>Hybrid</i> ARIMAX-FFNN	476,658	500,5

Tabel 4.27 menunjukkan bahwa model terbaik adalah FFNN karena memiliki nilai RMSE-out minimum yaitu 214,917 seperti pada Gambar 4.10 sebagai berikut:




**Gambar 4.11** Perbandingan Nilai RMSE Ketiga Metode

Hasil peramalan penjualan pertamax periode 12 bulan ke depan pada Agustus 2017-Juli 2018 menggunakan metode terbaik berdasarkan nilai RMSE-out minimum yaitu FFNN dapat dilihat pada Tabel 4.28 sebagai berikut:

**Tabel 4.28** Hasil Peramalan Penjualan Pertamax Agustus 2017-Juli 2018


t	Bulan, Tahun	Penjualan Pertamax
1	Agustus, 2017	12864,13
2	September, 2017	12539,53
3	Oktober, 2017	12663,6
4	Nopember, 2017	12869,27
5	Desember, 2017	12398,75
6	Januari, 2018	12057,26
7	Februari, 2018	11353,21
8	Maret, 2018	12174,99
9	April, 2018	12384,17
10	Mei, 2018	12018
11	Juni, 2018	11851,5
12	Juli, 2018	12957,51

Tabel 4.28 menunjukkan bahwa pada Juli 2018 didapatkan hasil ramalan penjualan bahan bakar pertamax mencapai puncak tertinggi yaitu sebesar 12.957,51 kl. Sedangkan ramalan penjualan bahan bakar pertamax terendah bulan Februari 2018 yaitu sebesar 11.851,5 kl.




**Gambar 4.12** Plot Data Penjualan Produk Pertamax Periode Januari 2010-Juli 2018

Gambar 4.12 terlihat bahwa pada hasil ramalan Juli 2018 terdapat kenaikan penjualan bahan bakar pertamax, sedangkan ramalan penjualan bahan bakar pertamax terendah bulan Februari 2018. Masing-masing *fits in-sample* dan *out-sample* dapat ditampilkan pada Gambar 4.13 sebagai berikut :



(a)



(b)

**Gambar 4.13** Plot *Fits-In* (a) dan *Fits-Out* (b) Data Penjualan Produk Pertamina

Gambar 4.13 terlihat bahwa data *fits-in* (a) dan *fits-out* (b) nilainya mendekati nilai penjualan *actual*. Hanya saja yang terlihat sedikit terdapat perbedaan antara *fits-out* dan data *actual* pada *out-sample*, tetapi tidak terlalu jauh nilainya.

*“Halaman ini sengaja dikosongkan”*

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan analisis yang telah dilakukan terhadap data penjualan produk bahan bakar pertamax di regional Surabaya, didapatkan kesimpulan sebagai berikut:

1. Model ARIMAX terbaik berdasarkan nilai RMSEP minimum adalah ARIMAX (1,1,0).
2. Pada FFNN menunjukkan bahwa kesesuaian pemilihan jumlah *neuron* pada *hidden layer* akan mempengaruhi nilai RMSE. Kriteria pemilihan model terbaik dilihat dari nilai RMSEP yang minimum yaitu terdapat pada 2 *hidden layer* dengan masing-masing *neuron* tiap *hidden layer* 25 dan 30.
3. Pada pemodelan *Hybrid* ARIMAX-FFNN menunjukkan bahwa 1 *hidden layer* dan jumlah *neuron* sebanyak 19 mempunyai nilai RMSEP minimum.
4. Pemilihan model terbaik menunjukkan bahwa model terbaik adalah *Feedforward Neural Network* (FFNN) karena memiliki nilai RMSEP minimum yaitu 214,917.

#### **5.2 Saran**

Saran yang dapat diberikan untuk penelitian selanjutnya adalah menggunakan data dengan periode yang lebih panjang, agar pengaruh penjualan pertalite lebih jelas terlihat polanya. Harapan dari pihak PT. Pertamina (Persero) Regional V Surabaya penjualan bahan bakar pertamax terus meningkat dibandingkan penjualan bahan bakar pertalite, tetapi ternyata penjualan pertalite sejak setahun diluncurkan penjualannya terus meningkat secara signifikan sehingga mengakibatkan penjualan pertamax menjadi menurun. Sebenarnya dengan menggunakan bahan bakar pertamax, secara tidak langsung dapat lebih irit karena oli, tune up, ruang bakar, dan kuras radiator lebih bersih serta tarikan lebih enteng dibandingkan bahan bakar pertalite. Jika sudah terlalu kotor, biaya servis kendaraan akan lebih mahal. Meskipun harga bahan bakar pertamax lebih mahal

jika dibandingkan dengan harga bahan bakar pertalite, tetapi manfaatnya sangat besar untuk kelangsungan mesin kendaraan. Maka, kebijakan yang harus dilakukan PT. Pertamina (Persero) Regional V Surabaya untuk meningkatkan penjualan salah satunya yaitu menurunkan harga. Bisa dikembangkan dengan menggunakan variabel *exogenous* adalah penjualan pertamax.

## DAFTAR PUSTAKA

- Chester, D.L., (1990). *Why Two Hidden Layers Are Better Than One*, in Proc. International Joint Conference on Neural Networks, 1990, Vol. 1, pp. 265 - 268.
- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis: with applications in R* (2nd ed.). Springer.
- Daniel, W. W. 1989. *Statistik Nonparametrik Terapan*. Diterjemahkan oleh ALEX Tri Kantjono W. Jakarta : PT. Gramedia.
- Fauset, L. (1994). *Fundamental of Neural Network: Architectures, Algorithm, and Applications*. New Jersey: Prentice Hall Inc.
- Faraway, J., & Chatfield, C. (1998). *Time Series Forecasting with Neural Networks: A Comparative Study using The Airline Data*. *Applied Statistics*, 231-250.
- Gujarati, D. N. (2004). *Basic Econometrics, Fourth Edition*. New York: The McGraw-Hill Companies.
- Jha, G. K. (2007). *Artificial Neural Networks And Its Applications*. *International Journal of Principal Scientist*. V 41-49.
- Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan (Menggunakan MATLAB dan Excel Link)*. Yogyakarta: Graha Ilmu.
- Kusumaningrum, O., Suhartono, & Haryono. (2012). *Peramalan Kebutuhan Bahan Bakar Premium di Depot Ampenan Dengan Metode Hibrida ARIMA-Neural Network Untuk Optimasi Persediaan*. *JURNAL SAINS DAN SENI POMITS Vol. 1, No.1*, 194-201.
- Pertamina. (2017). Dipetik Agustus 25, 2017, dari [www.pertamina.com](http://www.pertamina.com): <http://www.pertamina.com/our-business/hilir/pemasaran-dan-niaga/produk-dan-layanan/produk-konsumen/>
- Susanto, Y., (2016). *Pemodelan Curah Hujan dengan Pendekatan Model ARIMA, Feed Forward Neural Network dan Hybrid (ARIMA-NN) di Banyuwangi*. *JURNAL SAINS DAN SENI POMITS Vol. 5, No.2*, 145-150.



- Terasvirta, T., Lin, C., & Granger, C. (1993). *Power of Neural Networks Linearity Test. Journal of Time Series Analysis*, 14, 159-171.
- Tsay, R. S. (2005). *Analysis of Financial Time Series, Second Edition*. Canada: John Wiley & Sons, Inc.
- Wei, W. W. (2006). *Time Series Analysis: Univariate and Multivariate Methods, 2nd Edition*. New York: Pearson.
- Wulansari, R. E. & Suhartono. (2014). *Peramalan Netflow Uang Kartal dengan Metode ARIMAX dan Radial Basis Function Network (Studi Kasus Di Bank Indonesia. JURNAL SAINS DAN SENI POMITS Vol. 3, No.2, 73-78.*
- Zhang, G. P. (2003). *Time Series Forecasting using A Hybrid ARIMA and Neural Network Model. Neurocomputing*, 50, 159-175.
- Zhang, G. P., & Berardi, V. (1998). *An investigation of neural networks in thyroid function diagnosis. Health Care Management Science* 1(1), 29-37.

## LAMPIRAN

**Lampiran 1.** Data Penjualan Pertamina dan Paltalite di Regional V Surabaya

Bulan-Tahun	Pertamax (KL)	Pertalite (KL)	Dummy
JAN 2010	1168	0	0
FEB 2010	1320	0	0
MAR 2010	1080	0	0
APR 2010	1040	0	0
MAY 2010	832	0	0
JUN 2010	1433	0	0
JUL 2010	1088	0	0
AUG 2010	1480	0	0
SEP 2010	1568	0	0
OCT 2010	1856	0	0
NOV 2010	1720	0	0
DEC 2010	1744	0	0
JAN 2011	1464	0	0
FEB 2011	1216	0	0
MAR 2011	984	0	0
APR 2011	1224	0	0
MAY 2011	872	0	0
JUN 2011	864	0	0
JUL 2011	1312	0	0
AUG 2011	870	0	0
SEP 2011	1200	0	0
OCT 2011	1288	0	0
NOV 2011	996	0	0
DEC 2011	992	0	0
JAN 2012	1232	0	0
FEB 2012	1376	0	0
MAR 2012	920	0	0
APR 2012	668	0	0
MAY 2012	796	0	0
JUN 2012	1088	0	0
JUL 2012	1340	0	0
AUG 2012	1423	0	0

**Lampiran 1.** Data Penjualan Pertamina dan Peralite di Regional V Surabaya (Lanjutan)

Bulan-Tahun	Pertamax (KL)	Pertalite (KL)	Dummy
SEP 2012	1322	0	0
OCT 2012	1157	0	0
NOV 2012	1438	0	0
DEC 2012	1460	0	0
JAN 2013	1484	0	0
FEB 2013	1200	0	0
MAR 2013	1438	0	0
APR 2013	1480	0	0
MAY 2013	1821	0	0
JUN 2013	1689	0	0
JUL 2013	1940	0	0
AUG 2013	2029	0	0
SEP 2013	1982	0	0
OCT 2013	1972	0	0
NOV 2013	2062	0	0
DEC 2013	2169	0	0
JAN 2014	1705	0	0
FEB 2014	1777	0	0
MAR 2014	1982	0	0
APR 2014	2024	0	0
MAY 2014	1928	0	0
JUN 2014	2230	0	0
JUL 2014	1746	0	0
AUG 2014	2136	0	0
SEP 2014	2389	0	0
OCT 2014	2852	0	0
NOV 2014	3491	0	0
DEC 2014	5386	0	0
JAN 2015	7336	0	0
FEB 2015	7380	0	0
MAR 2015	7930	0	0
APR 2015	8276	0	0
MAY 2015	8584	0	0

**Lampiran 1. Data Penjualan Pertamina dan Peralite di Regional V Surabaya (Lanjutan)**

Bulan-Tahun	Pertamax (KL)	Pertalite (KL)	Dummy
JUN 2015	7232	0	0
JUL 2015	6898	684	1
AUG 2015	7077	3560	1
SEP 2015	7050	4400	1
OCT 2015	7391	4920	1
NOV 2015	7432	4832	1
DEC 2015	7796	4376	1
JAN 2016	8120	4848	1
FEB 2016	7523	4996	1
MAR 2016	9340	6960	1
APR 2016	10234	7848	1
MAY 2016	10818	9456	1
JUN 2016	10818	10896	1
JUL 2016	11514	12984	1
AUG 2016	12230	16456	1
SEP 2016	12288	17992	1
OCT 2016	12876	19528	1
NOV 2016	12440	19600	1
DEC 2016	12504	20016	1
JAN 2017	12084	19076	1
FEB 2017	11074	17368	1
MAR 2017	12658	20424	1
APR 2017	11828	19456	1
MAY 2017	12484	20408	1
JUN 2017	11648	18632	1
JUL 2017	12484	21992	1

**Lampiran 2. Analisis ANOVA Pengaruh Penjualan Pertalite Terhadap Pertamina Secara Serentak dan Individu**

**Regression Analysis: Pertamina (KL) versus Pertalite (KL), dummy**

The regression equation is

$$\text{Pertamax (KL)} = 2144 + 0.296 \text{ Pertalite (KL)} + 4507 \text{ dummy}$$

Predictor	Coef	SE Coef	T	P
Constant	2143.7	208.9	10.26	0.000
Pertalite (KL)	0.29626	0.04865	6.09	0.000
dummy	4506.9	725.8	6.21	0.000

S = 1697.11    R-Sq = 84.0%    R-Sq(adj) = 83.6%

**Analysis of Variance**

Source	DF	SS	MS	F	P
Regression	2	1326222103	663111052	230.23	0.000
Residual Error	88	253456175	2880184		
Total	90	1579678278			

Source	DF	Seq SS
Pertalite (KL)	1	1215155697
dummy	1	111066406


**Unusual Observations**

Obs	Pertalite (KL)	Pertamax (KL)	Fit	SE Fit	Residual	St Resid
61	0	7336	2144	209	5192	3.08R
62	0	7380	2144	209	5236	3.11R
63	0	7930	2144	209	5786	3.44R
64	0	8276	2144	209	6132	3.64R
65	0	8584	2144	209	6440	3.82R
66	0	7232	2144	209	5088	3.02R
67	684	6898	6853	666	45	0.03 X
68	3560	7077	7705	550	-628	-0.39 X
91	21992	12484	13166	574	-682	-0.43 X


R denotes an observation with a large standardized residual.  
X denotes an observation whose X value gives it large leverage.

### Lampiran 3. Hasil Proses Pemodelan ARIMAX

a. *Output* Minitab Uji Box-Cox Sebelum (i) dan Setelah Differencing (ii)



(i)



(ii)

b. Syntax Uji ADF untuk Stasioneritas Mean

(i). Syntax SAS ADF Non-Seasonal

```
data pertamax;
input zt;
datalines;
1168
1320
1080
1040
832
1433
```

**Lampiran 3.** Hasil Proses Pemodelan ARIMAX (Lanjutan)

b. Syntax Uji ADF untuk Stasioneritas Mean

(i). Syntax SAS ADF Non-Seasonal

1088
1480
1568
1856
1720
1744
1464
1216
984
1224
872
864
1312
870
1200
1288
996
992
1232
1376
920
668
796
1088
1340
1423
1322
1157
1438
1460
1484

**Lampiran 3.** Hasil Proses Pemodelan ARIMAX (Lanjutan)

b. Syntax Uji ADF untuk Stasioneritas Mean

(i). Syntax SAS ADF Non-Seasonal

1200
1288
996
992
1232
1376
920
668
796
1088
1340
1423
1322
1157
1438
1460
1484
1200
1438
1480
1821
1689
1940
2029
1982
1972
2062
2169
1705
1777
1982



**Lampiran 3.** Hasil Proses Pemodelan ARIMAX (Lanjutan)

b. Syntax Uji ADF untuk Stasioneritas Mean

(i). Syntax SAS ADF Non-Seasonal

2024
1928
2230
1746
2136
2389
2852
3491
5386
7336
7380
7930
8276
8584
7232
6898
7077
7050
7391
7432
7796
8120
7523
9340
10234
10818
10818
11514
12230
12288
12876

**Lampiran 3.** Hasil Proses Pemodelan ARIMAX (Lanjutan)

b. Syntax Uji ADF untuk Stasioneritas Mean

(i). Syntax SAS ADF Non-Seasonal

```
12440  
12504  
12084  
11074  
12658  
11828  
12484  
11648  
12484  
;  
proc arima data=pertamax;  
identify var=zt stationarity=(adf=(1));  
run;
```

(ii). Syntax SAS ADF Seasonal

```
data pertamax;  
input zt;  
datalines;  
1168  
1320  
1080  
1040  
832  
1433  
1088  
1480  
1568  
1856  
1720  
1744
```

**Lampiran 3.** Hasil Proses Pemodelan ARIMAX (Lanjutan)

(ii). Syntax SAS ADF Seasonal

1464

1216

984

1224

872

864

1312

870

1200

1288

996

992

1232

1376

920

668

796

1088

1340

1423

1322

1157

1438

1460

1484

1200

1438

1480

1821

1689

1940

2029

**Lampiran 3.** Hasil Proses Pemodelan ARIMAX (Lanjutan)

(ii). Syntax SAS ADF Seasonal

```
1982
2024
1928
2230
1746
2136
2389
2852
3491
5386
7336
7380
7930
8276
8584
7232
6898
7077
7050
7391
7432
7796
8120
7523
9340
10234
10818
10818
11514
12230
12288
```

### Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)

#### (ii). Syntax SAS ADF Seasonal

```

12876
12440
12504
12084
11074
12658
11828
12484
11648
12484
;
data pertamax;
set pertamax;
dzt=dif12(z);
run;
proc arima data=pertamax;
identify var=dzt stationarity=(adf=(12));
run;

```

#### c. Output SAS Uji ADF untuk Stasioneritas *Mean* (Non-seasonal)

Augmented Dickey-Fuller Unit Root Tests							
Type	Lags	Rho	Pr < Rho	Tau	Pr < Tau	F	Pr > F
Zero Mean	1	-45.6962	<.0001	-4.71	<.0001		
Single Mean	1	-52.3476	0.0008	-5.02	0.0001	12.63	0.0010
Trend	1	-56.7079	0.0003	-5.18	0.0003	13.42	0.0010

#### d. Output SAS Uji ADF untuk Stasioneritas *Mean* (seasonal)

Augmented Dickey-Fuller Unit Root Tests							
Type	Lags	Rho	Pr < Rho	Tau	Pr < Tau	F	Pr > F
Zero Mean	12	0.2433	0.7371	0.20	0.7417		
Single Mean	12	-1.4988	0.8320	-0.81	0.8099	0.95	0.8307
Trend	12	-9.1710	0.4661	-1.28	0.8849		

**Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)**

e. Syntax ARIMAX (1,1,0)

```
data pertamax;  
input zt x1t x2t;  
datalines;  
1168 0 0  
1320 0 0  
1080 0 0  
1040 0 0  
832 0 0  
1433 0 0  
1088 0 0  
1480 0 0  
1568 0 0  
1856 0 0  
1720 0 0  
1744 0 0  
1464 0 0  
1216 0 0  
984 0 0  
1224 0 0  
872 0 0  
864 0 0  
1312 0 0  
870 0 0  
1200 0 0  
1288 0 0  
996 0 0  
992 0 0  
1232 0 0  
1376 0 0  
920 0 0  
668 0 0  
796 0 0
```

**Lampiran 3.** Hasil Proses Pemodelan ARIMAX (Lanjutan)

e. Syntax ARIMAX (1,1,0)

1088	0	0
1340	0	0
1423	0	0
1322	0	0
1157	0	0
1438	0	0
1460	0	0
1484	0	0
1200	0	0
1438	0	0
1480	0	0
1821	0	0
1689	0	0
1940	0	0
2029	0	0
1982	0	0
1972	0	0
2062	0	0
2169	0	0
1705	0	0
1777	0	0
1982	0	0
2024	0	0
1928	0	0
2230	0	0
1746	0	0
2136	0	0
2389	0	0
2852	0	0
3491	0	0
5386	0	0
7336	0	0

**Lampiran 3.** Hasil Proses Pemodelan ARIMAX (Lanjutan)

e. Syntax ARIMAX (1,1,0)

```
7380 0 0
7930 0 0
8276 0 0
8584 0 0
7232 0 0
6898 684 1
7077 3560 1
7050 4400 1
7391 4920 1
7432 4832 1
7796 4376 1
8120 4848 1
7523 4996 1
9340 6960 1
10234 7848 1
10818 9456 1
10818 10896 1
11514 12984 1
. 16456 1
. 17992 1
. 19528 1
. 19600 1
. 20016 1
. 19076 1
. 17368 1
. 20424 1
. 19456 1
. 20408 1
. 18632 1
. 21992 1
;
proc arima data = pertamax;
```



### Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)

#### e. Syntax ARIMAX (1,1,0)

```
identify var=zt(1) crosscorr=(x1t(1) x2t(1)) nlag=36;
run;

estimate p=(1) input=(x1t x2t) noconstant method=cls;
forecast out = ramalan lead=12 printall;
outlier maxnum = 20 alpha=0.05;
run;

proc univariate data=ramalan normal;
var residual;
run;
```

#### f. Output SAS Estimasi Parameter ARIMA (1,1,0)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.32816	0.11557	2.84	0.0058	1	zt	0
NUM1	0.36294	0.11437	3.17	0.0022	0	x1t	0
NUM2	74.48486	455.64727	0.16	0.8706	0	x2t	0

#### g. Output SAS Uji White Noise Ljung-Box untuk ARIMA (1,1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.23	5	0.2039	-0.036	0.098	0.005	0.164	-0.156	-0.152
12	11.91	11	0.3707	-0.107	-0.139	-0.106	0.017	0.090	0.039
18	14.88	17	0.6043	0.034	-0.032	0.139	0.039	0.025	-0.078
24	16.27	23	0.8435	0.077	-0.012	0.018	0.030	-0.070	0.022
30	18.68	29	0.9291	0.053	-0.035	-0.076	0.009	0.097	-0.015
36	21.55	35	0.9636	0.019	0.023	-0.044	-0.054	0.113	-0.038

#### h. Output SAS Uji Distribusi Normal Kolmogorov-Smirnov untuk ARIMA (1,1,0)

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.929526	Pr < W	0.0003
Kolmogorov-Smirnov	D	0.10889	Pr > D	0.0220
Cramer-von Mises	W-Sq	0.184843	Pr > W-Sq	0.0083
Anderson-Darling	A-Sq	1.329285	Pr > A-Sq	<0.0050

### Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)

#### i. Syntax ARIMA (0,1,1)

```
data pertamax;  
input zt x1t x2t;  
datalines;  
1168 0 0  
1320 0 0  
1080 0 0  
1040 0 0  
832 0 0  
1433 0 0  
1088 0 0  
1480 0 0  
1568 0 0  
1856 0 0  
1720 0 0  
1744 0 0  
1464 0 0  
1216 0 0  
984 0 0  
1224 0 0  
872 0 0  
864 0 0  
1312 0 0  
870 0 0  
1200 0 0  
1288 0 0  
996 0 0  
992 0 0  
1232 0 0  
1376 0 0  
920 0 0  
668 0 0  
796 0 0
```

### Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)

#### i. Syntax ARIMA (0,1,1)

1340	0	0
1423	0	0
1322	0	0
1157	0	0
1438	0	0
1460	0	0
1484	0	0
1200	0	0
1438	0	0
1480	0	0
1821	0	0
1689	0	0
1940	0	0
2029	0	0
1982	0	0
1972	0	0
2062	0	0
2169	0	0
1705	0	0
1777	0	0
1982	0	0
2024	0	0
1928	0	0
2230	0	0
1746	0	0
2136	0	0
2389	0	0
2852	0	0
3491	0	0
5386	0	0
7336	0	0
7380	0	0

### Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)

#### i. Syntax ARIMA (0,1,1) (Lanjutan 2)

7930	0	0
8276	0	0
8584	0	0
7232	0	0
6898	684	1
7077	3560	1
7050	4400	1
7391	4920	1
7432	4832	1
7796	4376	1
8120	4848	1
7523	4996	1
9340	6960	1
10234	7848	1
10818	9456	1
10818	10896	1
11514	12984	1
.	16456	1
.	17992	1
.	19528	1
.	19600	1
.	20016	1
.	19076	1
.	17368	1
.	20424	1
.	19456	1
.	20408	1
.	18632	1
.	21992	1
;		
proc arima data = pertamax;		
identify var=zt(1) crosscorr=(x1t(1) x2t(1)) nlag=36;		

### Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)

#### i. Syntax ARIMA (0,1,1) (Lanjutan 3)

```
run;

estimate q=(1) input=(x1t x2t) noconstant method=cls;

forecast out = ramalan lead=12 printall;

outlier maxnum = 20 alpha=0.05;

run;

proc univariate data=ramalan normal;

var residual;

run;
```

#### j. Output SAS Estimasi Parameter ARIMA (0,1,1)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.23865	0.12145	-1.97	0.0531	1	zt	0
NUM1	0.33970	0.10672	3.18	0.0021	0	x1t	0
NUM2	-58.30678	487.78469	-0.12	0.9052	0	x2t	0

#### k. Output SAS Uji White Noise Ljung-Box untuk ARIMA (0,1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.64	5	0.0860	0.047	0.192	0.030	0.157	-0.156	-0.159
12	15.30	11	0.1694	-0.138	-0.148	-0.117	0.005	0.080	0.044
18	18.77	17	0.3418	0.053	-0.004	0.151	0.056	0.050	-0.059
24	20.10	23	0.6357	0.085	-0.001	0.024	0.028	-0.057	0.022
30	21.91	29	0.8238	0.039	-0.030	-0.064	0.010	0.089	-0.004
36	24.01	35	0.9195	0.022	0.021	-0.037	-0.048	0.094	-0.035

#### l. Output SAS Uji Distribusi Normal Kolmogorov-Smirnov untuk ARIMA (0,1,1)

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.915307	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.115922	Pr > D	0.0102
Cramer-von Mises	W-Sq	0.230938	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.601301	Pr > A-Sq	<0.0050

### Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)

m. Syntax SAS ARIMA (1,1,0) dengan Deteksi Outlier

```
data pertamax;  
input zt x1t x2t LS73 LS72 AO66 LS61;  
datalines;  
1168 0 0 0 0 0 0  
1320 0 0 0 0 0 0  
1080 0 0 0 0 0 0  
1040 0 0 0 0 0 0  
832 0 0 0 0 0 0  
1433 0 0 0 0 0 0  
1088 0 0 0 0 0 0  
1480 0 0 0 0 0 0  
1568 0 0 0 0 0 0  
1856 0 0 0 0 0 0  
1720 0 0 0 0 0 0  
1744 0 0 0 0 0 0  
1464 0 0 0 0 0 0  
1216 0 0 0 0 0 0  
984 0 0 0 0 0 0  
1224 0 0 0 0 0 0  
872 0 0 0 0 0 0  
864 0 0 0 0 0 0  
1312 0 0 0 0 0 0  
870 0 0 0 0 0 0  
1200 0 0 0 0 0 0  
1288 0 0 0 0 0 0  
996 0 0 0 0 0 0  
992 0 0 0 0 0 0  
1232 0 0 0 0 0 0  
1376 0 0 0 0 0 0  
920 0 0 0 0 0 0  
668 0 0 0 0 0 0  
796 0 0 0 0 0 0
```

**Lampiran 3.** Hasil Proses Pemodelan ARIMAX (Lanjutan)

m. Syntax SAS ARIMA (1,1,0) dengan Deteksi Outlier

1088	0	0	0	0	0	0
1340	0	0	0	0	0	0
1423	0	0	0	0	0	0
1322	0	0	0	0	0	0
1157	0	0	0	0	0	0
1438	0	0	0	0	0	0
1460	0	0	0	0	0	0
1484	0	0	0	0	0	0
1200	0	0	0	0	0	0
1438	0	0	0	0	0	0
1480	0	0	0	0	0	0
1821	0	0	0	0	0	0
1689	0	0	0	0	0	0
1940	0	0	0	0	0	0
2029	0	0	0	0	0	0
1982	0	0	0	0	0	0
1972	0	0	0	0	0	0
2062	0	0	0	0	0	0
2169	0	0	0	0	0	0
1705	0	0	0	0	0	0
1777	0	0	0	0	0	0
1982	0	0	0	0	0	0
2024	0	0	0	0	0	0
1928	0	0	0	0	0	0
2230	0	0	0	0	0	0
1746	0	0	0	0	0	0
2136	0	0	0	0	0	0
2389	0	0	0	0	0	0
2852	0	0	0	0	0	0
3491	0	0	0	0	0	0
5386	0	0	0	0	0	0
7336	0	0	0	0	0	1

**Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)**

m. Syntax SAS ARIMA (1,1,0) dengan Deteksi Outlier

7380	0	0	0	0	0	0
7930	0	0	0	0	0	0
8276	0	0	0	0	0	0
8584	0	0	0	0	0	0
7232	0	0	0	0	1	0
6898	684	1	0	0	0	0
7077	35601	0	0	0	0	0
7050	4400	1	0	0	0	0
7391	4920	1	0	0	0	0
7432	4832	1	0	0	0	0
7796	4376	1	0	1	0	0
8120	4848	1	1	0	0	0
7523	4996	1	0	0	0	0
9340	6960	1	0	0	0	0
10234	7848	1	0	0	0	0
10818	9456	1	0	0	0	0
10818	10896	1	0	0	0	0
11514	12984	1	0	0	0	0
.	16456	1	0	0	0	0
.	17992	1	0	0	0	0
.	19528	1	0	0	0	0
.	19600	1	0	0	0	0
.	20016	1	0	0	0	0
.	19076	1	0	0	0	0
.	17368	1	0	0	0	0
.	20424	1	0	0	0	0
.	19456	1	0	0	0	0
.	20408	1	0	0	0	0
.	18632	1	0	0	0	0
.	21992	1	0	0	0	0
;						
data pertamax;						



### Lampiran 3. Hasil Proses Pemodelan ARIMAX (Lanjutan)

#### m. Syntax SAS ARIMA (1,1,0) dengan Deteksi Outlier (Lanjutan 3)

```
set pertamax;
if_n_>=73 then LS73=1;else LS73=0;
if_n_>=72 then LS72=1;else LS72=0;
if_n_=66 then AO66=1;else AO66=0;
if_n_>=61 then LS61=1;else LS61=0;
run;
proc arima data = pertamax;
identify var=zt(1) crosscorr=(x1t(1) x2t(1) LS73(1) LS72(1) AO66(1) LS61(1))
nlag=36;
run;
estimate p=(1) input=(x1t x2t LS73 LS72 AO66 LS61) noconstant method=cls;
forecast out = ramalan lead=12 printall;
run;
outlier maxnum = 20 alpha=0.05;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=work.ramalan
outfile='D:\pertamax.xls'
dbms=excel
replace;
run;
```

n. Output SAS Estimasi dan Pengujian Parameter ARIMAX (1,1,0) dengan Deteksi Outlier

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.44056	0.10770	4.09	0.0001	1	zt	0
NUM1	0.32313	0.10195	3.17	0.0023	0	x1t	0
NUM2	-1648.4	644.20477	-2.56	0.0126	0	x2t	0
NUM3	913.35894	280.73393	3.25	0.0017	0	LS73	0
NUM4	653.44574	279.34010	2.34	0.0221	0	LS72	0
NUM5	-1365.3	387.08884	-3.53	0.0007	0	AD66	0
NUM6	771.75284	215.62549	3.58	0.0006	0	LS61	0
Variance Estimate				150906.3			
Std Error Estimate				388.4666			
AIC				1158.124			
SBC				1174.621			
Number of Residuals				78			
* AIC and SBC do not include log determinant.							

n. Output SAS Uji White Noise ARIMA (1,1,0) dengan Deteksi Outlier

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.20	5	0.1454	-0.070	0.162	-0.076	0.206	-0.092	0.100
12	17.36	11	0.0977	-0.186	-0.179	-0.012	0.152	-0.014	-0.107
18	26.40	17	0.0675	0.172	-0.025	0.211	0.019	0.056	-0.116
24	28.93	23	0.1828	0.136	-0.036	0.030	-0.010	0.039	-0.037
30	33.09	29	0.2741	0.091	-0.079	-0.009	-0.050	0.121	-0.043
36	40.44	35	0.2426	0.079	-0.011	-0.047	-0.061	0.188	-0.060

o. Output SAS Uji Distribusi Normal ARIMAX (1,1,0) dengan Deteksi Outlier

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.937686	Pr < W	0.0009
Kolmogorov-Smirnov	D	0.09993	Pr > D	0.0525
Cramer-von Mises	W-Sq	0.092041	Pr > W-Sq	0.1437
Anderson-Darling	A-Sq	0.73109	Pr > A-Sq	0.0556

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network*

a. Syntax SPSS *Feedforward Neural Network* (1-25-30-1) :

```

DATASET ACTIVATE DataSet1.
set seed 123
*Multilayer Perceptron Network.
MLP Pertamax_In (MLEVEL=S) WITH PACF
/RESCALE COVARIATE=STANDARDIZED
DEPENDENT=STANDARDIZED


```

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

a. Syntax SPSS *Feedforward Neural Network* (1-25-30-1) :

```
/PARTITION VARIABLE=Partition  
/ARCHITECTURE AUTOMATIC=NO HIDDENLAYERS=2  
(NUMUNITS=25,30) HIDDENFUNCTION=SIGMOID  
OUTPUTFUNCTION=IDENTITY  
/CRITERIA TRAINING=BATCH  
OPTIMIZATION=SCALEDCONJUGATE  
LAMBDAINITIAL=0.0000005  
SIGMAINITIAL=0.00005 INTERVALCENTER=0  
INTERVALOFFSET=0.5 MEMSIZE=1000  
/PRINT CPS NETWORKINFO SUMMARY CLASSIFICATION  
SOLUTION  
/PLOT NETWORK PREDICTED  
/SAVE PREDVAL  
/STOPPINGRULES ERRORSTEPS= 1 (DATA=AUTO)  
TRAININGTIMER=ON (MAXTIME=15) MAXEPOCHS=AUTO  
ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010  
/MISSING USERMISSING=EXCLUDE .
```

b. Output SPSS *Feedforward Neural Network* (1-25-30-1) :



**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

b. *Output SPSS Feedforward Neural Network (1-25-30-1) :*

Model Summary		
Training	Sum of Squares Error	48.307
	Relative Error	1.271
	Stopping Rule Used	1 consecutive step(s) with no decrease in error <sup>a</sup>
	Training Time	0:00:00.08
Testing	Sum of Squares Error	2.579
	Relative Error	. <sup>b</sup>

Prediktor		Output Layer Pertamax_In	Prediktor	Output Layer Pertamax_In	Prediktor	Output Layer Pertamax_In
<i>Hidden Layer 2</i>	(Bias)	0,042				
	H(2:1)	-0,409	H(2:11)	0,179	H(2:21)	0,231
	H(2:2)	-0,122	H(2:12)	0,169	H(2:22)	-0,011
	H(2:3)	-0,375	H(2:13)	0,098	H(2:23)	0,286
	H(2:4)	0,299	H(2:14)	0,154	H(2:24)	0,023
	H(2:5)	0,181	H(2:15)	-0,039	H(2:25)	0,274
	H(2:6)	-0,263	H(2:16)	0,213	H(2:26)	-0,452
	H(2:7)	-0,050	H(2:17)	0,031	H(2:27)	-0,327
	H(2:8)	-0,256	H(2:18)	0,342	H(2:28)	-0,470
	H(2:9)	0,450	H(2:19)	0,437	H(2:29)	-0,013
	H(2:10)	0,421	H(2:20)	0,399	H(2:30)	-0,459

Prediktor		<i>Hidden Layer 2</i>							
		H(2:1)	H(2:2)	H(2:3)	H(2:4)	H(2:5)	H(2:6)	H(2:7)	H(2:8)
<i>Hidden Layer 1</i>	(Bias)	0,324	-0,466	-0,170	0,272	-0,012	0,408	0,028	0,187
	H(1:1)	-0,337	-0,007	-0,394	-0,410	0,310	0,434	-0,025	-0,383
	H(1:2)	0,345	-0,317	-0,419	0,222	-0,038	0,042	0,079	-0,137
	H(1:3)	0,283	-0,391	0,009	0,160	-0,177	-0,252	-0,300	-0,479
	H(1:4)	0,143	-0,113	-0,013	-0,141	0,234	0,458	-0,130	0,432
	H(1:5)	-0,351	0,158	-0,450	0,398	0,341	-0,208	0,086	0,053
	H(1:6)	0,381	-0,352	0,465	-0,349	-0,198	0,256	0,151	-0,152
	H(1:7)	-0,146	-0,005	-0,127	0,289	0,499	-0,373	-0,375	-0,272
	H(1:8)	0,026	0,237	-0,375	-0,331	0,333	-0,312	0,020	0,178
	H(1:9)	0,230	0,475	0,158	0,036	0,315	0,359	-0,473	-0,214
	H(1:10)	-0,075	0,105	-0,227	0,407	0,210	0,064	0,475	0,435
	H(1:11)	0,121	-0,422	0,486	0,047	-0,265	-0,168	0,235	0,410
	H(1:12)	-0,031	-0,282	0,296	0,419	0,427	-0,004	-0,018	-0,033
	H(1:13)	-0,413	-0,121	-0,215	0,461	0,291	0,481	-0,398	0,181
	H(1:14)	-0,129	0,345	0,099	0,142	0,476	-0,281	-0,098	-0,382
	H(1:15)	-0,163	-0,227	-0,309	0,033	0,051	0,111	-0,382	-0,127
	H(1:16)	0,487	0,335	-0,041	0,433	0,113	-0,399	-0,316	-0,163
	H(1:17)	0,039	0,072	-0,065	-0,285	0,225	0,192	0,428	-0,148
	H(1:18)	-0,207	-0,312	-0,383	0,075	0,011	0,334	-0,299	-0,136

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

Prediktor		<i>Hidden Layer 2</i>							
		H(2:1)	H(2:2)	H(2:3)	H(2:4)	H(2:5)	H(2:6)	H(2:7)	H(2:8)
	H(1:19)	-0,337	0,154	0,044	-0,097	0,378	0,477	0,381	-0,464
	H(1:20)	0,410	0,357	0,201	-0,114	-0,170	-0,145	-0,456	0,001
	H(1:21)	-0,052	-0,401	-0,140	-0,077	0,378	0,150	-0,386	-0,351
	H(1:22)	-0,424	0,490	-0,243	0,002	-0,445	0,120	-0,298	-0,457
	H(1:23)	0,462	0,072	0,167	-0,413	-0,340	0,084	0,397	0,173
	H(1:24)	0,461	-0,426	-0,207	0,378	-0,309	0,86	0,072	-0,427
	H(1:25)	-0,447	0,480	-0,460	0,083	-0,085	0,155	0,225	0,138
Prediktor		<i>Hidden Layer 2</i>							
		H(2:9)	H(2:10)	H(2:11)	H(2:12)	H(2:13)	H(2:14)	H(2:15)	H(2:16)
<i>Hidden Layer 1</i>	(Bias)	0,172	-0,300	-0,292	0,373	-0,264	-0,383	-0,018	0,140
	H(1:1)	-0,284	-0,359	0,018	0,074	-0,334	0,207	0,463	0,070
	H(1:2)	-0,496	-0,085	0,104	-0,147	0,135	-0,187	0,478	-0,265
	H(1:3)	-0,311	-0,203	0,217	0,040	-0,335	-0,489	-0,061	-0,168
	H(1:4)	0,471	-0,397	-0,333	-0,451	-0,007	-0,176	-0,231	0,009
	H(1:5)	-0,421	0,007	0,248	0,039	0,406	-0,265	-0,220	0,089
	H(1:6)	0,443	0,330	0,029	-0,457	0,299	0,413	0,235	0,309
	H(1:7)	-0,033	0,020	-0,427	-0,258	0,334	-0,339	0,435	0,441
	H(1:8)	0,129	-0,031	0,380	-0,273	-0,329	0,248	-0,491	-0,012
	H(1:9)	-0,192	0,324	-0,091	-0,145	-0,214	-0,339	0,152	0,184
	H(1:10)	-0,010	0,367	-0,181	0,239	-0,450	0,248	0,331	-0,437
	H(1:11)	0,089	-0,402	-0,093	0,376	-0,374	-0,339	0,304	0,320
	H(1:12)	-0,161	0,052	0,489	-0,428	-0,078	0,147	-0,037	-0,279
	H(1:13)	-0,282	0,086	-0,418	0,416	0,111	-0,028	0,338	-0,377
	H(1:14)	-0,407	-0,396	-0,280	-0,087	-0,239	0,039	-0,154	0,471
	H(1:15)	-0,061	0,173	-0,073	0,223	0,189	0,021	0,017	0,212
	H(1:16)	-0,324	0,025	-0,373	-0,120	-0,062	-0,173	0,203	-0,262
	H(1:17)	-0,465	0,063	0,132	-0,261	-0,306	0,183	0,370	-0,147
	H(1:18)	0,010	0,167	-0,334	-0,374	0,224	0,020	0,258	-0,494
	H(1:19)	0,269	-0,400	-0,224	-0,294	-0,479	-0,185	0,157	0,186
	H(1:20)	0,076	-0,239	0,095	0,065	0,466	-0,492	-0,061	-0,055
	H(1:21)	0,125	0,133	-0,412	0,428	-0,106	0,019	-0,015	0,030
	H(1:22)	-0,192	0,138	0,239	0,343	-0,190	-0,183	-0,392	-0,077
	H(1:23)	-0,076	0,286	-0,235	-0,075	0,130	0,093	0,175	0,252
	H(1:24)	0,435	0,261	0,309	0,227	-0,014	0,288	0,189	-0,337
	H(1:25)	0,217	-0,163	-0,318	-0,266	-0,251	-0,075	-0,259	0,143


  

Prediktor		<i>Hidden Layer 2</i>							
		H(2:17)	H(2:18)	H(2:19)	H(2:20)	H(2:21)	H(2:22)	H(2:23)	H(2:24)
<i>Hidden Layer 1</i>	(Bias)	0,336	0,098	0,424	-0,037	-0,449	-0,399	-0,117	-0,263
	H(1:1)	0,063	-0,274	-0,097	0,191	-0,421	-0,313	0,034	-0,167
	H(1:2)	0,390	-0,190	-0,310	-0,496	-0,016	-0,388	-0,343	0,029
	H(1:3)	-0,401	-0,076	0,268	-0,175	0,105	0,463	-0,233	-0,367
	H(1:4)	0,315	0,229	0,211	-0,262	0,412	0,164	-0,449	0,314
	H(1:5)	0,156	0,171	-0,205	0,318	0,380	0,481	0,322	0,208
	H(1:6)	-0,221	0,472	0,147	0,447	0,360	0,491	-0,324	0,176
	H(1:7)	0,221	-0,357	0,242	0,314	0,397	0,167	0,203	0,456
	H(1:8)	0,034	0,116	0,113	-0,286	-0,435	0,323	0,337	0,159
	H(1:9)	0,381	0,170	0,331	0,232	-0,301	0,347	-0,150	-0,109
	H(1:10)	0,299	0,181	0,271	0,114	-0,392	-0,092	-0,373	0,116
	H(1:11)	-0,013	0,168	0,381	-0,485	0,414	0,146	0,041	0,434
	H(1:12)	0,464	-0,277	0,201	-0,144	-0,081	0,072	-0,117	-0,466
	H(1:13)	0,265	0,002	-0,100	-0,033	-0,264	-0,432	-0,238	-0,357
	H(1:14)	0,044	0,343	0,489	-0,121	0,444	-0,172	0,476	0,436
	H(1:15)	-0,137	-0,070	-0,239	0,223	-0,491	0,436	-0,237	-0,304
	H(1:16)	-0,267	-0,395	0,219	0,298	-0,234	0,342	-0,369	0,284
	H(1:17)	0,250	-0,454	0,323	-0,322	-0,263	-0,219	-0,003	0,499
	H(1:18)	0,147	-0,063	0,212	-0,292	0,326	-0,420	-0,118	-0,438

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

b. Output SPSS Feedforward Neural Network (1-25-30-1) : (Lanjutan 3)

Prediktor		<i>Hidden Layer 2</i>					
		H(2:25)	H(2:26)	H(2:27)	H(2:28)	H(2:29)	H(2:30)
<i>Hidden Layer 1</i>	(Bias)	0,253	-0,204	-0,351	-0,288	0,450	-0,475
	H(1:1)	-0,369	0,202	0,360	-0,101	-0,457	0,320
	H(1:2)	-0,482	0,320	0,092	0,009	-0,323	-0,347
	H(1:3)	-0,207	0,076	-0,215	-0,096	-0,228	0,081
	H(1:4)	-0,355	0,484	-0,134	-0,221	-0,371	0,394
	H(1:5)	0,403	-0,034	-0,285	-0,387	0,385	-0,298
	H(1:6)	0,021	0,163	0,397	0,437	-0,266	0,080
	H(1:7)	-0,081	0,030	0,063	0,292	0,228	0,205
	H(1:8)	0,182	-0,327	-0,041	-0,248	-0,151	-0,035
	H(1:9)	0,182	0,219	0,438	0,058	0,282	-0,251
	H(1:10)	-0,013	0,207	-0,127	-0,372	0,371	-0,182
	H(1:11)	-0,268	-0,326	-0,245	-0,178	0,062	-0,333
	H(1:12)	0,418	0,379	0,492	-0,239	0,163	-0,033
	H(1:13)	-0,019	0,467	-0,118	-0,443	0,177	-0,224
	H(1:14)	0,080	0,264	-0,201	0,276	-0,408	-0,298
	H(1:15)	-0,359	0,036	0,308	0,262	-0,206	0,339
	H(1:16)	0,328	-0,473	0,291	0,178	-0,242	0,248
	H(1:17)	-0,248	0,213	-0,063	-0,056	0,337	0,187
	H(1:18)	0,035	-0,413	-0,184	-0,141	0,161	0,030
	H(1:19)	0,133	-0,033	0,244	-0,432	-0,256	0,072
	H(1:20)	0,051	0,309	-0,208	0,007	0,368	-0,164
	H(1:21)	-0,430	-0,102	-0,484	0,214	-0,453	-0,007
	H(1:22)	-0,380	0,423	0,401	0,355	-0,080	-0,172
	H(1:23)	-0,105	0,078	0,015	0,346	0,448	-0,307
	H(1:24)	0,002	0,289	0,413	0,024	0,023	0,189
	H(1:25)	0,103	-0,142	-0,378	-0,261	-0,495	-0,414



**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) :

*Layer* tersembunyi kedua:

$$\begin{aligned}
 f_1^{h_2} &= b_1^{h_2} + w_1^{h_1} f_1^{h_1} + w_2^{h_1} f_2^{h_1} + w_3^{h_1} f_3^{h_1} + w_4^{h_1} f_4^{h_1} + w_5^{h_1} f_5^{h_1} + w_6^{h_1} f_6^{h_1} + w_7^{h_1} f_7^{h_1} \\
 &+ w_8^{h_1} f_8^{h_1} + w_9^{h_1} f_9^{h_1} + w_{10}^{h_1} f_{10}^{h_1} + w_{11}^{h_1} f_{11}^{h_1} + w_{12}^{h_1} f_{12}^{h_1} + w_{13}^{h_1} f_{13}^{h_1} + w_{14}^{h_1} f_{14}^{h_1} \\
 &+ w_{15}^{h_1} f_{15}^{h_1} + w_{16}^{h_1} f_{16}^{h_1} + w_{17}^{h_1} f_{17}^{h_1} + w_{18}^{h_1} f_{18}^{h_1} + w_{19}^{h_1} f_{19}^{h_1} + w_{20}^{h_1} f_{20}^{h_1} + w_{21}^{h_1} f_{21}^{h_1} \\
 &+ w_{22}^{h_1} f_{22}^{h_1} + w_{23}^{h_1} f_{23}^{h_1} + w_{24}^{h_1} f_{24}^{h_1} + w_{25}^{h_1} f_{25}^{h_1} \\
 &= 0,324 + 0,337f_1^{h_1} + 0,345f_2^{h_1} + 0,283f_3^{h_1} + 0,143f_4^{h_1} - 0,351f_5^{h_1} + \\
 &0,381f_6^{h_1} - 0,146f_7^{h_1} + 0,026f_8^{h_1} + 0,230f_9^{h_1} - 0,075f_{10}^{h_1} + 0,121f_{11}^{h_1} - \\
 &0,031f_{12}^{h_1} - 0,413f_{13}^{h_1} - 0,129f_{14}^{h_1} - 0,163f_{15}^{h_1} + 0,487f_{16}^{h_1} + 0,039f_{17}^{h_1} - \\
 &0,207f_{18}^{h_1} - 0,337f_{19}^{h_1} + 0,410f_{20}^{h_1} - 0,052f_{21}^{h_1} - 0,424f_{22}^{h_1} + 0,462f_{23}^{h_1} + \\
 &0,461f_{24}^{h_1} - 0,447f_{25}^{h_1} \\
 f_2^{h_2} &= -0,466 - 0,007f_1^{h_1} - 0,317f_2^{h_1} - 0,391f_3^{h_1} - 0,113f_4^{h_1} + 0,158f_5^{h_1} \\
 &- 0,352f_6^{h_1} - 0,005f_7^{h_1} + 0,237f_8^{h_1} + 0,475f_9^{h_1} + 0,105f_{10}^{h_1} - 0,422f_{11}^{h_1} - \\
 &0,282f_{12}^{h_1} - 0,121f_{13}^{h_1} + 0,345f_{14}^{h_1} - 0,277f_{15}^{h_1} + 0,335f_{16}^{h_1} + \\
 &0,072f_{17}^{h_1} - 0,312f_{18}^{h_1} + 0,154f_{19}^{h_1} + 0,357f_{20}^{h_1} - 0,401f_{21}^{h_1} + \\
 &0,490f_{22}^{h_1} + 0,072f_{23}^{h_1} - 0,426f_{24}^{h_1} + 0,480f_{25}^{h_1} \\
 f_3^{h_2} &= -0,170 - 0,394f_1^{h_1} - 0,419f_2^{h_1} + 0,009f_3^{h_1} - 0,013f_4^{h_1} - 0,450f_5^{h_1} + \\
 &0,465f_6^{h_1} - 0,127f_7^{h_1} - 0,375f_8^{h_1} + 0,158f_9^{h_1} - 0,227f_{10}^{h_1} + 0,486f_{11}^{h_1} + \\
 &0,296f_{12}^{h_1} - 0,215f_{13}^{h_1} + 0,099f_{14}^{h_1} - 0,309f_{15}^{h_1} - 0,041f_{16}^{h_1} - \\
 &0,065f_{17}^{h_1} - 0,383f_{18}^{h_1} + 0,044f_{19}^{h_1} + 0,201f_{20}^{h_1} - 0,140f_{21}^{h_1} \\
 &- 0,243f_{22}^{h_1} + 0,167f_{23}^{h_1} - 0,207f_{24}^{h_1} - 0,460f_{25}^{h_1} \\
 f_4^{h_2} &= 0,272 - 0,410f_1^{h_1} + 0,222f_2^{h_1} + 0,160f_3^{h_1} - 0,141f_4^{h_1} + 0,398f_5^{h_1} - \\
 &0,349f_6^{h_1} + 0,289f_7^{h_1} - 0,310f_8^{h_1} + 0,036f_9^{h_1} + 0,407f_{10}^{h_1} + 0,047f_{11}^{h_1} + \\
 &0,419f_{12}^{h_1} + 0,461f_{13}^{h_1} + 0,142f_{14}^{h_1} + 0,033f_{15}^{h_1} + 0,433f_{16}^{h_1} - 0,285f_{17}^{h_1} \\
 &+ 0,075f_{18}^{h_1} - 0,097f_{19}^{h_1} - 0,114f_{20}^{h_1} - 0,077f_{21}^{h_1} + 0,002f_{22}^{h_1} - 0,413f_{23}^{h_1} \\
 &+ 0,378f_{24}^{h_1} + 0,083f_{25}^{h_1}
 \end{aligned}$$

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) : (Lanjutan 1)

*Layer* tersembunyi kedua:

$$\begin{aligned} f_5^{h_2} = & -0,012 + 0,310f_1^{h_1} - 0,038f_2^{h_1} - 0,177f_3^{h_1} + 0,234f_4^{h_1} + 0,341f_5^{h_1} - \\ & 0,198f_6^{h_1} + 0,499f_7^{h_1} + 0,333f_8^{h_1} + 0,315f_9^{h_1} + 0,210f_{10}^{h_1} - 0,265f_{11}^{h_1} + \\ & 0,427f_{12}^{h_1} + 0,291f_{13}^{h_1} + 0,476f_{14}^{h_1} + 0,051f_{15}^{h_1} + 0,113f_{16}^{h_1} + \\ & 0,225f_{17}^{h_1} + 0,011f_{18}^{h_1} + 0,378f_{19}^{h_1} - 0,170f_{20}^{h_1} + 0,378f_{21}^{h_1} \\ & - 0,445f_{22}^{h_1} - 0,340f_{23}^{h_1} - 0,390f_{24}^{h_1} - 0,085f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_6^{h_2} = & 0,480 + 0,434f_1^{h_1} + 0,042f_2^{h_1} - 0,252f_3^{h_1} + 0,458f_4^{h_1} - 0,208f_5^{h_1} + \\ & 0,256f_6^{h_1} - 0,373f_7^{h_1} - 0,312f_8^{h_1} + 0,359f_9^{h_1} + 0,064f_{10}^{h_1} - 0,168f_{11}^{h_1} - \\ & 0,004f_{12}^{h_1} + 0,418f_{13}^{h_1} - 0,281f_{14}^{h_1} - 0,111f_{15}^{h_1} - 0,399f_{16}^{h_1} + \\ & 0,192f_{17}^{h_1} + 0,334f_{18}^{h_1} + 0,477f_{19}^{h_1} - 0,145f_{20}^{h_1} + 0,150f_{21}^{h_1} + \\ & 0,120f_{22}^{h_1} + 0,084f_{23}^{h_1} + 0,086f_{24}^{h_1} + 0,155f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_7^{h_2} = & 0,028 - 0,025f_1^{h_1} + 0,079f_2^{h_1} - 0,302f_3^{h_1} - 0,130f_4^{h_1} + 0,086f_5^{h_1} + \\ & 0,151f_6^{h_1} - 0,375f_7^{h_1} + 0,020f_8^{h_1} - 0,473f_9^{h_1} + 0,475f_{10}^{h_1} + 0,235f_{11}^{h_1} - \\ & 0,018f_{12}^{h_1} - 0,398f_{13}^{h_1} - 0,098f_{14}^{h_1} - 0,382f_{15}^{h_1} - 0,316f_{16}^{h_1} + \\ & 0,428f_{17}^{h_1} - 0,299f_{18}^{h_1} + 0,381f_{19}^{h_1} - 0,456f_{20}^{h_1} - 0,386f_{21}^{h_1} - \\ & 0,298f_{22}^{h_1} + 0,397f_{23}^{h_1} + 0,072f_{24}^{h_1} + 0,225f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_8^{h_2} = & 0,187 - 0,383f_1^{h_1} - 0,137f_2^{h_1} - 0,479f_3^{h_1} + 0,432f_4^{h_1} + 0,053f_5^{h_1} - \\ & 0,152f_6^{h_1} - 0,272f_7^{h_1} + 0,178f_8^{h_1} - 0,214f_9^{h_1} + 0,435f_{10}^{h_1} + 0,410f_{11}^{h_1} - \\ & 0,033f_{12}^{h_1} + 0,181f_{13}^{h_1} - 0,382f_{14}^{h_1} - 0,127f_{15}^{h_1} - 0,163f_{16}^{h_1} - \\ & 0,148f_{17}^{h_1} + 0,136f_{18}^{h_1} + 0,464f_{19}^{h_1} + 0,001f_{20}^{h_1} - 0,351f_{21}^{h_1} - \\ & 0,457f_{22}^{h_1} + 0,173f_{23}^{h_1} - 0,427f_{24}^{h_1} + 0,138f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_9^{h_2} = & 0,172 - 0,284f_1^{h_1} - 0,496f_2^{h_1} - 0,311f_3^{h_1} + 0,471f_4^{h_1} - 0,421f_5^{h_1} + \\ & 0,443f_6^{h_1} - 0,033f_7^{h_1} + 0,129f_8^{h_1} - 0,192f_9^{h_1} - 0,010f_{10}^{h_1} + 0,089f_{11}^{h_1} - \\ & 0,161f_{12}^{h_1} - 0,282f_{13}^{h_1} - 0,407f_{14}^{h_1} - 0,061f_{15}^{h_1} - 0,324f_{16}^{h_1} - \\ & - 0,465f_{17}^{h_1} + 0,010f_{18}^{h_1} + 0,269f_{19}^{h_1} + 0,076f_{20}^{h_1} + 0,125f_{21}^{h_1} - \\ & 0,192f_{22}^{h_1} - 0,076f_{23}^{h_1} + 0,435f_{24}^{h_1} + 0,217f_{25}^{h_1} \end{aligned}$$



**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) : (Lanjutan 2)

*Layer* tersembunyi kedua:

$$\begin{aligned} f_{10}^{h_2} = & -0,300 - 0,359f_1^{h_1} - 0,085f_2^{h_1} - 0,203f_3^{h_1} - 0,397f_4^{h_1} + 0,007f_5^{h_1} + \\ & 0,330f_6^{h_1} + 0,020f_7^{h_1} - 0,031f_8^{h_1} + 0,324f_9^{h_1} + 0,367f_{10}^{h_1} - 0,402f_{11}^{h_1} \\ & + 0,052f_{12}^{h_1} + 0,086f_{13}^{h_1} - 0,396f_{14}^{h_1} + 0,173f_{15}^{h_1} + 0,025f_{16}^{h_1} + \\ & 0,063f_{17}^{h_1} + 0,167f_{18}^{h_1} - 0,400f_{19}^{h_1} - 0,239f_{20}^{h_1} + 0,133f_{21}^{h_1} + \\ & 0,138f_{22}^{h_1} + 0,286f_{23}^{h_1} + 0,261f_{24}^{h_1} - 0,163f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{11}^{h_2} = & -0,292 + 0,018f_1^{h_1} + 0,104f_2^{h_1} + 0,217f_3^{h_1} - 0,333f_4^{h_1} + 0,248f_5^{h_1} + \\ & 0,029f_6^{h_1} - 0,427f_7^{h_1} + 0,380f_8^{h_1} - 0,091f_9^{h_1} - 0,181f_{10}^{h_1} - 0,093f_{11}^{h_1} + \\ & 0,489f_{12}^{h_1} - 0,418f_{13}^{h_1} - 0,280f_{14}^{h_1} - 0,073f_{15}^{h_1} - 0,073f_{16}^{h_1} + \\ & 0,132f_{17}^{h_1} - 0,334f_{18}^{h_1} - 0,224f_{19}^{h_1} + 0,095f_{20}^{h_1} - 0,412f_{21}^{h_1} + \\ & 0,239f_{22}^{h_1} - 0,235f_{23}^{h_1} + 0,309f_{24}^{h_1} - 0,318f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{12}^{h_2} = & 0,373 + 0,074f_1^{h_1} - 0,147f_2^{h_1} + 0,040f_3^{h_1} - 0,451f_4^{h_1} + 0,039f_5^{h_1} \\ & - 0,457f_6^{h_1} - 0,258f_7^{h_1} - 0,273f_8^{h_1} - 0,145f_9^{h_1} + 0,239f_{10}^{h_1} + 0,376f_{11}^{h_1} \\ & - 0,428f_{12}^{h_1} + 0,416f_{13}^{h_1} - 0,087f_{14}^{h_1} + 0,223f_{15}^{h_1} - 0,120f_{16}^{h_1} \\ & - 0,261f_{17}^{h_1} - 0,374f_{18}^{h_1} - 0,294f_{19}^{h_1} + 0,065f_{20}^{h_1} + 0,428f_{21}^{h_1} + \\ & 0,343f_{22}^{h_1} - 0,075f_{23}^{h_1} + 0,227f_{24}^{h_1} - 0,266f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{13}^{h_2} = & -0,264 - 0,334f_1^{h_1} + 0,135f_2^{h_1} - 0,335f_3^{h_1} - 0,007f_4^{h_1} + 0,406f_5^{h_1} + \\ & 0,229f_6^{h_1} + 0,344f_7^{h_1} - 0,329f_8^{h_1} - 0,214f_9^{h_1} - 0,450f_{10}^{h_1} - 0,374f_{11}^{h_1} \\ & - 0,078f_{12}^{h_1} + 0,111f_{13}^{h_1} - 0,239f_{14}^{h_1} + 0,189f_{15}^{h_1} - 0,062f_{16}^{h_1} \\ & - 0,261f_{17}^{h_1} + 0,224f_{18}^{h_1} - 0,479f_{19}^{h_1} + 0,466f_{20}^{h_1} - 0,106f_{21}^{h_1} \\ & - 0,190f_{22}^{h_1} + 0,130f_{23}^{h_1} - 0,014f_{24}^{h_1} - 0,251f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{14}^{h_2} = & -0,383 + 0,207f_1^{h_1} - 0,187f_2^{h_1} - 0,489f_3^{h_1} - 0,176f_4^{h_1} - 0,265f_5^{h_1} + \\ & 0,413f_6^{h_1} - 0,339f_7^{h_1} + 0,248f_8^{h_1} - 0,339f_9^{h_1} + 0,147f_{10}^{h_1} - 0,028f_{11}^{h_1} + \\ & 0,309f_{12}^{h_1} + 0,021f_{13}^{h_1} - 0,173f_{14}^{h_1} + 0,183f_{15}^{h_1} + 0,020f_{16}^{h_1} \\ & - 0,185f_{17}^{h_1} - 0,492f_{18}^{h_1} + 0,019f_{19}^{h_1} - 0,183f_{20}^{h_1} + 0,092f_{21}^{h_1} + \\ & 0,288f_{22}^{h_1} - 0,075f_{23}^{h_1} - 0,074f_{24}^{h_1} - 0,382f_{25}^{h_1} \end{aligned}$$

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) : (Lanjutan 3)

Layer tersembunyi kedua:

$$\begin{aligned} f_{15}^{h_2} = & -0,018 + 0,463f_1^{h_1} + 0,478f_2^{h_1} - 0,061f_3^{h_1} - 0,231f_4^{h_1} - 0,220f_5^{h_1} + \\ & 0,235f_6^{h_1} + 0,435f_7^{h_1} - 0,491f_8^{h_1} + 0,152f_9^{h_1} + 0,331f_{10}^{h_1} + 0,304f_{11}^{h_1} \\ & - 0,037f_{12}^{h_1} + 0,338f_{13}^{h_1} - 0,154f_{14}^{h_1} + 0,017f_{15}^{h_1} + 0,203f_{16}^{h_1} + \\ & 0,370f_{17}^{h_1} + 0,258f_{18}^{h_1} + 0,157f_{19}^{h_1} - 0,061f_{20}^{h_1} - 0,015f_{21}^{h_1} \\ & - 0,392f_{22}^{h_1} + 0,175f_{23}^{h_1} + 0,189f_{24}^{h_1} - 0,259f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{16}^{h_2} = & 0,140 + 0,070f_1^{h_1} - 0,265f_2^{h_1} - 0,168f_3^{h_1} + 0,009f_4^{h_1} + 0,890f_5^{h_1} + \\ & 0,309f_6^{h_1} + 0,441f_7^{h_1} - 0,012f_8^{h_1} + 0,184f_9^{h_1} - 0,437f_{10}^{h_1} + 0,320f_{11}^{h_1} \\ & - 0,279f_{12}^{h_1} - 0,337f_{13}^{h_1} + 0,471f_{14}^{h_1} + 0,212f_{15}^{h_1} - 0,262f_{16}^{h_1} \\ & - 0,147f_{17}^{h_1} - 0,494f_{18}^{h_1} + 0,186f_{19}^{h_1} - 0,055f_{20}^{h_1} + 0,030f_{21}^{h_1} \\ & - 0,077f_{22}^{h_1} + 0,252f_{23}^{h_1} - 0,337f_{24}^{h_1} + 0,143f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{17}^{h_2} = & 0,336 + 0,063f_1^{h_1} + 0,390f_2^{h_1} - 0,401f_3^{h_1} + 0,315f_4^{h_1} + 0,156f_5^{h_1} - \\ & 0,221f_6^{h_1} + 0,221f_7^{h_1} + 0,034f_8^{h_1} + 0,381f_9^{h_1} + 0,299f_{10}^{h_1} - 0,013f_{11}^{h_1} + \\ & 0,464f_{12}^{h_1} + 0,265f_{13}^{h_1} + 0,044f_{14}^{h_1} - 0,137f_{15}^{h_1} - 0,267f_{16}^{h_1} + \\ & 0,250f_{17}^{h_1} + 0,147f_{18}^{h_1} + 0,331f_{19}^{h_1} + 0,461f_{20}^{h_1} - 0,241f_{21}^{h_1} + 0,287f_{22}^{h_1} \\ & - 0,276f_{23}^{h_1} - 0,273f_{24}^{h_1} + 0,009f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{18}^{h_2} = & 0,098 - 0,274f_1^{h_1} - 0,190f_2^{h_1} - 0,076f_3^{h_1} + 0,229f_4^{h_1} + 0,171f_5^{h_1} + \\ & 0,472f_6^{h_1} - 0,357f_7^{h_1} - 0,116f_8^{h_1} + 0,170f_9^{h_1} + 0,181f_{10}^{h_1} + 0,168f_{11}^{h_1} \\ & - 0,277f_{12}^{h_1} + 0,002f_{13}^{h_1} + 0,343f_{14}^{h_1} - 0,070f_{15}^{h_1} - 0,395f_{16}^{h_1} \\ & - 0,454f_{17}^{h_1} - 0,063f_{18}^{h_1} - 0,357f_{19}^{h_1} - 0,272f_{20}^{h_1} + 0,478f_{21}^{h_1} + \\ & 0,403f_{22}^{h_1} + 0,122f_{23}^{h_1} - 0,396f_{24}^{h_1} - 0,019f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{19}^{h_2} = & 0,424 - 0,097f_1^{h_1} - 0,310f_2^{h_1} + 0,268f_3^{h_1} + 0,211f_4^{h_1} - 0,205f_5^{h_1} + \\ & 0,147f_6^{h_1} + 0,242f_7^{h_1} + 0,113f_8^{h_1} + 0,331f_9^{h_1} + 0,271f_{10}^{h_1} + 0,381f_{11}^{h_1} + \\ & 0,201f_{12}^{h_1} - 0,100f_{13}^{h_1} + 0,489f_{14}^{h_1} - 0,239f_{15}^{h_1} + 0,219f_{16}^{h_1} + \\ & 0,323f_{17}^{h_1} + 0,212f_{18}^{h_1} + 0,374f_{19}^{h_1} + 0,095f_{20}^{h_1} + 0,390f_{21}^{h_1} \\ & - 0,293f_{22}^{h_1} - 0,074f_{23}^{h_1} - 0,194f_{24}^{h_1} - 0,039f_{25}^{h_1} \end{aligned}$$

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) : (Lanjutan 4)

*Layer* tersembunyi kedua:

$$\begin{aligned} f_{20}^{h_2} = & -0,037 + 0,191f_1^{h_1} - 0,496f_2^{h_1} - 0,175f_3^{h_1} - 0,262f_4^{h_1} + 0,318f_5^{h_1} + \\ & 0,447f_6^{h_1} + 0,314f_7^{h_1} - 0,286f_8^{h_1} + 0,232f_9^{h_1} + 0,114f_{10}^{h_1} - 0,485f_{11}^{h_1} \\ & - 0,485f_{12}^{h_1} - 0,144f_{13}^{h_1} - 0,121f_{14}^{h_1} + 0,223f_{15}^{h_1} + 0,298f_{16}^{h_1} \\ & - 0,322f_{17}^{h_1} - 0,292f_{18}^{h_1} - 0,393f_{19}^{h_1} - 0,390f_{20}^{h_1} + 0,056f_{21}^{h_1} \\ & - 0,121f_{22}^{h_1} + 0,326f_{23}^{h_1} + 0,179f_{24}^{h_1} - 0,438f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{21}^{h_2} = & -0,449 - 0,421f_1^{h_1} - 0,016f_2^{h_1} + 0,105f_3^{h_1} + 0,412f_4^{h_1} + 0,380f_5^{h_1} + \\ & 0,360f_6^{h_1} + 0,397f_7^{h_1} - 0,435f_8^{h_1} - 0,301f_9^{h_1} - 0,392f_{10}^{h_1} + 0,414f_{11}^{h_1} \\ & - 0,081f_{12}^{h_1} - 0,264f_{13}^{h_1} + 0,444f_{14}^{h_1} - 0,491f_{15}^{h_1} - 0,234f_{16}^{h_1} \\ & - 0,263f_{17}^{h_1} + 0,326f_{18}^{h_1} + 0,096f_{19}^{h_1} + 0,191f_{20}^{h_1} + 0,012f_{21}^{h_1} + \\ & 0,229f_{22}^{h_1} + 0,263f_{23}^{h_1} - 0,274f_{24}^{h_1} - 0,352f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{22}^{h_2} = & -0,339 - 0,313f_1^{h_1} - 0,388f_2^{h_1} + 0,463f_3^{h_1} + 0,164f_4^{h_1} + 0,481f_5^{h_1} + \\ & 0,491f_6^{h_1} + 0,167f_7^{h_1} + 0,323f_8^{h_1} + 0,347f_9^{h_1} - 0,092f_{10}^{h_1} + 0,146f_{11}^{h_1} + \\ & 0,072f_{12}^{h_1} - 0,172f_{13}^{h_1} - 0,432f_{14}^{h_1} + 0,436f_{15}^{h_1} + 0,342f_{16}^{h_1} \\ & - 0,219f_{17}^{h_1} - 0,420f_{18}^{h_1} + 0,006f_{19}^{h_1} - 0,002f_{20}^{h_1} + 0,073f_{21}^{h_1} \\ & - 0,396f_{22}^{h_1} + 0,486f_{23}^{h_1} - 0,086f_{24}^{h_1} + 0,003f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{23}^{h_2} = & -0,117 + 0,034f_1^{h_1} - 0,343f_2^{h_1} - 0,233f_3^{h_1} - 0,449f_4^{h_1} + 0,322f_5^{h_1} \\ & - 0,324f_6^{h_1} + 0,203f_7^{h_1} + 0,337f_8^{h_1} - 0,150f_9^{h_1} - 0,373f_{10}^{h_1} + 0,041f_{11}^{h_1} \\ & - 0,117f_{12}^{h_1} - 0,238f_{13}^{h_1} + 0,476f_{14}^{h_1} - 0,237f_{15}^{h_1} - 0,369f_{16}^{h_1} \\ & - 0,003f_{17}^{h_1} - 0,118f_{18}^{h_1} - 0,454f_{19}^{h_1} - 0,331f_{20}^{h_1} + 0,275f_{21}^{h_1} + \\ & 0,255f_{22}^{h_1} - 0,454f_{23}^{h_1} - 0,084f_{24}^{h_1} + 0,212f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{24}^{h_2} = & -0,263 - 0,167f_1^{h_1} - 0,029f_2^{h_1} - 0,367f_3^{h_1} + 0,314f_4^{h_1} + 0,208f_5^{h_1} + \\ & 0,176f_6^{h_1} + 0,456f_7^{h_1} + 0,159f_8^{h_1} - 0,109f_9^{h_1} + 0,116f_{10}^{h_1} + 0,434f_{11}^{h_1} \\ & - 0,466f_{12}^{h_1} - 0,357f_{13}^{h_1} + 0,436f_{14}^{h_1} - 0,304f_{15}^{h_1} + 0,284f_{16}^{h_1} + \\ & 0,499f_{17}^{h_1} - 0,438f_{18}^{h_1} - 0,250f_{19}^{h_1} - 0,152f_{20}^{h_1} + 0,183f_{21}^{h_1} \\ & - 0,479f_{22}^{h_1} + 0,423f_{23}^{h_1} + 0,108f_{24}^{h_1} - 0,132f_{25}^{h_1} \end{aligned}$$

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) : (Lanjutan 5)

Layer tersembunyi kedua :

$$\begin{aligned} f_{25}^{h_2} = & -0,253 - 0,369f_1^{h_1} - 0,482f_2^{h_1} - 0,207f_3^{h_1} - 0,355f_4^{h_1} + 0,403f_5^{h_1} + \\ & 0,021f_6^{h_1} - 0,081f_7^{h_1} + 0,182f_8^{h_1} + 0,182f_9^{h_1} - 0,013f_{10}^{h_1} - 0,268f_{11}^{h_1} + \\ & 0,418f_{12}^{h_1} - 0,019f_{13}^{h_1} + 0,080f_{14}^{h_1} - 0,359f_{15}^{h_1} + 0,328f_{16}^{h_1} \\ & - 0,248f_{17}^{h_1} + 0,035f_{18}^{h_1} + 0,133f_{19}^{h_1} + 0,051f_{20}^{h_1} - 0,430f_{21}^{h_1} \\ & - 0,380f_{22}^{h_1} - 0,105f_{23}^{h_1} + 0,002f_{24}^{h_1} + 0,103f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{26}^{h_2} = & -0,204 + 0,202f_1^{h_1} + 0,320f_2^{h_1} + 0,076f_3^{h_1} + 0,484f_4^{h_1} - 0,034f_5^{h_1} + \\ & 0,163f_6^{h_1} + 0,030f_7^{h_1} - 0,327f_8^{h_1} + 0,219f_9^{h_1} + 0,207f_{10}^{h_1} - 0,326f_{11}^{h_1} + \\ & 0,379f_{12}^{h_1} + 0,467f_{13}^{h_1} + 0,264f_{14}^{h_1} + 0,036f_{15}^{h_1} - 0,473f_{16}^{h_1} - 0,213f_{17}^{h_1} \\ & - 0,413f_{18}^{h_1} - 0,033f_{19}^{h_1} + 0,309f_{20}^{h_1} - 0,102f_{21}^{h_1} + 0,423f_{22}^{h_1} + \\ & 0,078f_{23}^{h_1} + 0,289f_{24}^{h_1} - 0,142f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{27}^{h_2} = & -0,351 + 0,360f_1^{h_1} + 0,092f_2^{h_1} - 0,215f_3^{h_1} - 0,134f_4^{h_1} - 0,285f_5^{h_1} + \\ & 0,397f_6^{h_1} + 0,063f_7^{h_1} - 0,041f_8^{h_1} + 0,438f_9^{h_1} - 0,127f_{10}^{h_1} - 0,245f_{11}^{h_1} + \\ & 0,492f_{12}^{h_1} - 0,118f_{13}^{h_1} - 0,201f_{14}^{h_1} + 0,308f_{15}^{h_1} + 0,291f_{16}^{h_1} \\ & - 0,063f_{17}^{h_1} - 0,184f_{18}^{h_1} + 0,244f_{19}^{h_1} - 0,208f_{20}^{h_1} - 0,484f_{21}^{h_1} + \\ & 0,401f_{22}^{h_1} + 0,015f_{23}^{h_1} + 0,413f_{24}^{h_1} - 0,378f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{28}^{h_2} = & -0,288 - 0,101f_1^{h_1} + 0,009f_2^{h_1} - 0,096f_3^{h_1} - 0,221f_4^{h_1} - 0,387f_5^{h_1} + \\ & 0,437f_6^{h_1} + 0,292f_7^{h_1} - 0,248f_8^{h_1} + 0,058f_9^{h_1} - 0,372f_{10}^{h_1} - 0,178f_{11}^{h_1} \\ & - 0,239f_{12}^{h_1} - 0,443f_{13}^{h_1} + 0,276f_{14}^{h_1} + 0,262f_{15}^{h_1} + 0,178f_{16}^{h_1} \\ & - 0,056f_{17}^{h_1} - 0,141f_{18}^{h_1} - 0,432f_{19}^{h_1} + 0,007f_{20}^{h_1} - 0,214f_{21}^{h_1} + \\ & 0,355f_{22}^{h_1} + 0,346f_{23}^{h_1} + 0,024f_{24}^{h_1} - 0,261f_{25}^{h_1} \end{aligned}$$

$$\begin{aligned} f_{29}^{h_2} = & -0,450 - 0,457f_1^{h_1} - 0,323f_2^{h_1} - 0,228f_3^{h_1} - 0,371f_4^{h_1} + 0,385f_5^{h_1} \\ & - 0,266f_6^{h_1} + 0,228f_7^{h_1} - 0,151f_8^{h_1} + 0,282f_9^{h_1} + 0,371f_{10}^{h_1} + 0,062f_{11}^{h_1} \\ & + 0,168f_{12}^{h_1} + 0,177f_{13}^{h_1} - 0,408f_{14}^{h_1} - 0,206f_{15}^{h_1} - 0,242f_{16}^{h_1} + \\ & 0,337f_{17}^{h_1} + 0,161f_{18}^{h_1} - 0,256f_{19}^{h_1} + 0,368f_{20}^{h_1} - 0,453f_{21}^{h_1} \\ & - 0,080f_{22}^{h_1} + 0,448f_{23}^{h_1} + 0,023f_{24}^{h_1} - 0,495f_{25}^{h_1} \end{aligned}$$

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) : (Lanjutan 6)

- *Layer* tersembunyi kedua :

$$\begin{aligned} f_{30}^{h_2} = & -0,475 + 0,320f_1^{h_1} - 0,347f_2^{h_1} + 0,081f_3^{h_1} + 0,394f_4^{h_1} - 0,298f_5^{h_1} + \\ & 0,080f_6^{h_1} + 0,205f_7^{h_1} - 0,035f_8^{h_1} - 0,251f_9^{h_1} - 0,182f_{10}^{h_1} - 0,333f_{11}^{h_1} \\ & - 0,033f_{12}^{h_1} - 0,224f_{13}^{h_1} - 0,298f_{14}^{h_1} + 0,339f_{15}^{h_1} + 0,248f_{16}^{h_1} + \\ & 0,187f_{17}^{h_1} + 0,030f_{18}^{h_1} + 0,072f_{19}^{h_1} - 0,164f_{20}^{h_1} - 0,007f_{21}^{h_1} \\ & - 0,172f_{22}^{h_1} - 0,370f_{23}^{h_1} + 0,189f_{24}^{h_1} - 0,414f_{25}^{h_1} \end{aligned}$$

- *Layer* tersembunyi kesatu:

$$f_1^{h_1} = f(b_1 + w_1 Y_{t-1}) = 0,071 - 0,200 Y_{t-1}$$

$$f_2^{h_1} = f(b_2 + w_2 Y_{t-1}) = -0,438 + 0,016 Y_{t-1}$$

$$f_3^{h_1} = f(b_3 + w_3 Y_{t-1}) = -0,382 - 0,136 Y_{t-1}$$

$$f_4^{h_1} = f(b_4 + w_4 Y_{t-1}) = -0,225 + 0,068 Y_{t-1}$$

$$f_5^{h_1} = f(b_5 + w_5 Y_{t-1}) = -0,407 + 0,298 Y_{t-1}$$

$$f_6^{h_1} = f(b_6 + w_6 Y_{t-1}) = -0,419 + 0,259 Y_{t-1}$$

$$f_7^{h_1} = f(b_7 + w_7 Y_{t-1}) = 0,287 + 0,432 Y_{t-1}$$

$$f_8^{h_1} = f(b_8 + w_8 Y_{t-1}) = -0,454 + 0,007 Y_{t-1}$$

$$f_9^{h_1} = f(b_9 + w_9 Y_{t-1}) = 0,104 + 0,441 Y_{t-1}$$

$$f_{10}^{h_1} = f(b_{10} + w_{10} Y_{t-1}) = -0,442 - 0,190 Y_{t-1}$$

$$f_{11}^{h_1} = f(b_{11} + w_{11} Y_{t-1}) = -0,410 - 0,127 Y_{t-1}$$

$$f_{12}^{h_1} = f(b_{12} + w_{12} Y_{t-1}) = -0,408 - 0,062 Y_{t-1}$$

$$f_{13}^{h_1} = f(b_{13} + w_{13} Y_{t-1}) = 0,245 - 0,020 Y_{t-1}$$

$$f_{14}^{h_1} = f(b_{14} + w_{14} Y_{t-1}) = -0,072 + 0,182 Y_{t-1}$$

$$f_{15}^{h_1} = f(b_{15} + w_{15} Y_{t-1}) = 0,399 - 0,129 Y_{t-1}$$

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) : (Lanjutan 7)

- *Layer* tersembunyi kesatu:

$$f_{16}^{h_1} = f(b_{16} + w_{16}Y_{t-1}) = -0,144 + 0,352 Y_{t-1}$$

$$f_{17}^{h_1} = f(b_{17} + w_{17}Y_{t-1}) = 0,066 + 0,013 Y_{t-1}$$

$$f_{18}^{h_1} = f(b_{18} + w_{18}Y_{t-1}) = -0,488 + 0,124 Y_{t-1}$$

$$f_{19}^{h_1} = f(b_{19} + w_{19}Y_{t-1}) = -0,373 + 0,045 Y_{t-1}$$

$$f_{20}^{h_1} = f(b_{20} + w_{20}Y_{t-1}) = 0,244 - 0,341 Y_{t-1}$$

$$f_{21}^{h_1} = f(b_{21} + w_{21}Y_{t-1}) = -0,426 + 0,439 Y_{t-1}$$

$$f_{22}^{h_1} = f(b_{22} + w_{22}Y_{t-1}) = -0,118 + 0,232 Y_{t-1}$$

$$f_{23}^{h_1} = f(b_{23} + w_{23}Y_{t-1}) = -0,283 - 0,411 Y_{t-1}$$

$$f_{24}^{h_1} = f(b_{24} + w_{24}Y_{t-1}) = -0,498 + 0,495 Y_{t-1}$$

$$f_{25}^{h_1} = f(b_{25} + w_{25}Y_{t-1}) = 0,405 - 0,012 Y_{t-1}$$

dimana:

$$f(b_1 + w_1Y_{t-1}) = \frac{1}{1+e^{-(b_1+w_1Y_{t-1})}} = \frac{1}{1+e^{-(0,071 - 0,200Y_{t-1})}}$$

$$f(b_2 + w_2Y_{t-1}) = \frac{1}{1+e^{-(b_2+w_2Y_{t-1})}} = \frac{1}{1+e^{-(0,438 + 0,016Y_{t-1})}}$$

$$f(b_3 + w_3Y_{t-1}) = \frac{1}{1+e^{-(b_3+w_3Y_{t-1})}} = \frac{1}{1+e^{-(0,382 - 0,136Y_{t-1})}}$$

$$f(b_4 + w_4Y_{t-1}) = \frac{1}{1+e^{-(b_4+w_4Y_{t-1})}} = \frac{1}{1+e^{-(0,225 + 0,068Y_{t-1})}}$$

$$f(b_5 + w_5Y_{t-1}) = \frac{1}{1+e^{-(b_5+w_5Y_{t-1})}} = \frac{1}{1+e^{-(0,407 + 0,298Y_{t-1})}}$$

$$f(b_6 + w_6Y_{t-1}) = \frac{1}{1+e^{-(b_6+w_6Y_{t-1})}} = \frac{1}{1+e^{-(0,419 + 0,259Y_{t-1})}}$$

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) : (Lanjutan 8)

$$f(b_7 + w_7 Y_{t-1}) = \frac{1}{1+e^{-(b_7+w_7 Y_{t-1})}} = \frac{1}{1+e^{-(0,287 + 0,432 Y_{t-1})}}$$

$$f(b_8 + w_8 Y_{t-1}) = \frac{1}{1+e^{-(b_8+w_8 Y_{t-1})}} = \frac{1}{1+e^{-( -0,454 + 0,007 Y_{t-1})}}$$

$$f(b_9 + w_9 Y_{t-1}) = \frac{1}{1+e^{-(b_9+w_9 Y_{t-1})}} = \frac{1}{1+e^{-(0,104 + 0,441 Y_{t-1})}}$$

$$f(b_{10} + w_{10} Y_{t-1}) = \frac{1}{1+e^{-(b_{10}+w_{10} Y_{t-1})}} = \frac{1}{1+e^{-( -0,442 - 0,190 Y_{t-1})}}$$

$$f(b_{11} + w_{11} Y_{t-1}) = \frac{1}{1+e^{-(b_{11}+w_{11} Y_{t-1})}} = \frac{1}{1+e^{-( -0,410 - 0,127 Y_{t-1})}}$$

$$f(b_{12} + w_{12} Y_{t-1}) = \frac{1}{1+e^{-(b_{12}+w_{12} Y_{t-1})}} = \frac{1}{1+e^{-( -0,408 - 0,062 Y_{t-1})}}$$

$$f(b_{13} + w_{13} Y_{t-1}) = \frac{1}{1+e^{-(b_{13}+w_{13} Y_{t-1})}} = \frac{1}{1+e^{-(0,245 - 0,020 Y_{t-1})}}$$

$$f(b_{14} + w_{14} Y_{t-1}) = \frac{1}{1+e^{-(b_{14}+w_{14} Y_{t-1})}} = \frac{1}{1+e^{-( -0,072 + 0,182 Y_{t-1})}}$$

$$f(b_{15} + w_{15} Y_{t-1}) = \frac{1}{1+e^{-(b_{15}+w_{15} Y_{t-1})}} = \frac{1}{1+e^{-(0,399 - 0,129 Y_{t-1})}}$$

$$f(b_{16} + w_{16} Y_{t-1}) = \frac{1}{1+e^{-(b_{16}+w_{16} Y_{t-1})}} = \frac{1}{1+e^{-( -0,144 + 0,352 Y_{t-1})}}$$

$$f(b_{17} + w_{17} Y_{t-1}) = \frac{1}{1+e^{-(b_{17}+w_{17} Y_{t-1})}} = \frac{1}{1+e^{-(0,066 + 0,013 Y_{t-1})}}$$

$$f(b_{18} + w_{18} Y_{t-1}) = \frac{1}{1+e^{-(b_{18}+w_{18} Y_{t-1})}} = \frac{1}{1+e^{-( -0,488 + 0,124 Y_{t-1})}}$$

$$f(b_{19} + w_{19} Y_{t-1}) = \frac{1}{1+e^{-(b_{19}+w_{19} Y_{t-1})}} = \frac{1}{1+e^{-( -0,373 + 0,045 Y_{t-1})}}$$

**Lampiran 4.** Hasil Proses Pemodelan *Feedforward Neural Network* (Lanjutan)

c. Pemodelan *Feedforward Neural Network* (1-25-30-1) : (Lanjutan 9)

$$f(b_{20} + w_{20}Y_{t-1}) = \frac{1}{1+e^{-(b_{20}+w_{20}Y_{t-1})}} = \frac{1}{1+e^{-(0,244 - 0,341 Y_{t-1})}}$$

$$f(b_{21} + w_{21}Y_{t-1}) = \frac{1}{1+e^{-(b_{21}+w_{21}Y_{t-1})}} = \frac{1}{1+e^{-(0,426 + 0,439 Y_{t-1})}}$$

$$f(b_{22} + w_{22}Y_{t-1}) = \frac{1}{1+e^{-(b_{22}+w_{22}Y_{t-1})}} = \frac{1}{1+e^{-(0,118 + 0,232 Y_{t-1})}}$$

$$f(b_{23} + w_{23}Y_{t-1}) = \frac{1}{1+e^{-(b_{23}+w_{23}Y_{t-1})}} = \frac{1}{1+e^{-(0,283 - 0,411 Y_{t-1})}}$$

$$f(b_{24} + w_{24}Y_{t-1}) = \frac{1}{1+e^{-(b_{24}+w_{24}Y_{t-1})}} = \frac{1}{1+e^{-(0,498 + 0,495 Y_{t-1})}}$$

$$f(b_{25} + w_{25}Y_{t-1}) = \frac{1}{1+e^{-(b_{25}+w_{25}Y_{t-1})}} = \frac{1}{1+e^{-(0,405 - 0,012 Y_{t-1})}}$$

**Lampiran 5.** Hasil Proses Pemodelan *Hybrid ARIMAX-Feedforward Neural Network*

a. Syntax SPSS *Hybrid Feedforward Neural Network* (1-19-1) :

```
DATASET ACTIVATE DataSet1.
set seed 123
*Multilayer Perceptron Network.
  MLP Residual_ARIMAX_Fixed (MLEVEL=S) WITH Input_NN_Fixed
  /RESCALE COVARIATE=STANDARDIZED DEPENDENT=STANDARDIZED
  /PARTITION VARIABLE=Partition
  /ARCHITECTURE AUTOMATIC=NO HIDDENLAYERS=1 (NUMUNITS=19)
  HIDDENFUNCTION=SIGMOID
  OUTPUTFUNCTION=IDENTITY
  /CRITERIA TRAINING=BATCH OPTIMIZATION=SCALEDCONJUGATE
  LAMBDAINITIAL=0.0000005
  SIGMAINITIAL=0.00005 INTERVALCENTER=0 INTERVALOFFSET=0.5
  MEMSIZE=1000
  /PRINT CPS NETWORKINFO SUMMARY SOLUTION
  /PLOT NETWORK PREDICTED
```




**Lampiran 5.** Hasil Proses Pemodelan *Hybrid ARIMAX-Feedforward Neural Network*  
(Lanjutan)

a. *Syntax SPSS Hybrid Feedforward Neural Network* (1-19-1) : (Lanjutan)

```
/SAVE PREDVAL
/STOPPINGRULES ERRORSTEPS= 1 (DATA=AUTO) TRAININGTIMER=ON
(MAXTIME=15) MAXEPOCHS=AUTO
ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010
/MISSING USERMISSING=EXCLUDE .
```

b. *Output SPSS Hybrid Feedforward Neural Network* (1-19-1) :



**Model Summary**

Training	Sum of Squares Error	37.656
	Relative Error	.991
	Stopping Rule Used	1 consecutive step(s) with no decrease in error <sup>a</sup>
	Training Time	0:00:00.03
Testing	Sum of Squares Error	6.006
	Relative Error	1.048

Dependent Variable: Residual\_ARIMAX\_Fixed

a. Error computations are based on the testing sample.

**Lampiran 5.** Hasil Proses Pemodelan *Hybrid ARIMAX-Feedforward Neural Network*  
(Lanjutan)

b. *Output SPSS Hybrid Feedforward Neural Network (1-19-1) : (Lanjutan)*

Prediktor		Output Layer Pertamax_In	Prediktor	Output Layer Pertamax_In
Hidden Layer 1	(Bias)	0,257	H(1:10)	-0,482
	H(1:1)	-0,188	H(1:11)	0,344
	H(1:2)	0,981	H(1:12)	-0,686
	H(1:3)	-0,201	H(1:13)	0,436
	H(1:4)	0,294	H(1:14)	0,547
	H(1:5)	-0,442	H(1:15)	-0,143
	H(1:6)	-0,129	H(1:16)	0,049
	H(1:7)	-0,120	H(1:17)	-0,065
	H(1:8)	0,591	H(1:18)	-0,112
	H(1:9)	-0,153	H(1:19)	-0,415

Prediktor		Hidden Layer 1				
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)
Input Layer	(Bias)	-0,164	-0,759	0,438	-0,483	0,493
	Input NN	-0,316	-1,767	-0,257	-0,420	0,999
Prediktor		Hidden Layer 1				
		H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)
Input Layer	(Bias)	0,643	0,340	0,196	-0,025	0,243
	Input NN	0,970	-0,235	0,134	-0,010	-0,672
Prediktor		Hidden Layer 1				
		H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)
Input Layer	(Bias)	-0,070	0,660	-0,285	0,063	-0,186
	Input NN	0,279	-0,496	-0,423	0,455	-0,131
Prediktor		Hidden Layer 1				
		H(1:16)	H(1:17)	H(1:18)	H(1:19)	
Input Layer	(Bias)	-0,166	-0,205	0,009	0,455	
	Input NN	-0,082	-0,261	-0,156	0,463	

c. Pemodelan *Hybrid Feedforward Neural Network (1-19-1) :*

*Layer* tersembunyi kesatu :

$$f_1^{h_1} = f(b_1 + w_1 e_{t-1}) = -0,164 - 0,316 e_{t-1}$$

$$f_2^{h_1} = f(b_2 + w_2 e_{t-1}) = -0,759 - 1,767 e_{t-1}$$

$$f_3^{h_1} = f(b_3 + w_3 e_{t-1}) = 0,438 - 0,257 e_{t-1}$$

$$f_4^{h_1} = f(b_4 + w_4 e_{t-1}) = -0,483 - 0,420 e_{t-1}$$

$$f_5^{h_1} = f(b_5 + w_5 e_{t-1}) = 0,493 + 0,999 e_{t-1}$$

$$f_6^{h_1} = f(b_6 + w_6 e_{t-1}) = 0,643 + 0,970 e_{t-1}$$

**Lampiran 5.** Hasil Proses Pemodelan *Hybrid ARIMAX-Feedforward Neural Network*

(Lanjutan)

c. Pemodelan *Hybrid Feedforward Neural Network* (1-19-1) : (Lanjutan 1)

*Layer* tersembunyi kesatu :

$$f_7^{h_1} = f(b_7 + w_7 e_{t-1}) = 0,340 - 0,235 e_{t-1}$$

$$f_8^{h_1} = f(b_8 + w_8 e_{t-1}) = 0,196 + 0,134 e_{t-1}$$

$$f_9^{h_1} = f(b_9 + w_9 e_{t-1}) = -0,025 - 0,010 e_{t-1}$$

$$f_{10}^{h_1} = f(b_{10} + w_{10} e_{t-1}) = 0,243 - 0,672 e_{t-1}$$

$$f_{11}^{h_1} = f(b_{11} + w_{11} e_{t-1}) = -0,070 + 0,279 e_{t-1}$$

$$f_{12}^{h_1} = f(b_{12} + w_{12} e_{t-1}) = -0,660 - 0,496 e_{t-1}$$

$$f_{13}^{h_1} = f(b_{13} + w_{13} e_{t-1}) = -0,285 - 0,423 e_{t-1}$$

$$f_{14}^{h_1} = f(b_{14} + w_{14} e_{t-1}) = 0,063 + 0,455 e_{t-1}$$

$$f_{15}^{h_1} = f(b_{15} + w_{15} e_{t-1}) = -0,186 - 0,131 e_{t-1}$$

$$f_{16}^{h_1} = f(b_{16} + w_{16} e_{t-1}) = -0,166 - 0,082 e_{t-1}$$

$$f_{17}^{h_1} = f(b_{17} + w_{17} e_{t-1}) = -0,205 - 0,261 e_{t-1}$$

$$f_{18}^{h_1} = f(b_{18} + w_{18} e_{t-1}) = 0,009 - 0,156 e_{t-1}$$

$$f_{19}^{h_1} = f(b_{19} + w_{19} e_{t-1}) = 0,455 - 0,463 e_{t-1}$$

dimana:

$$f(b_1 + w_1 e_{t-1}) = \frac{1}{1 + e^{-(b_1 + w_1 e_{t-1})}} = \frac{1}{1 + e^{-(-0,164 - 0,316 e_{t-1})}}$$

$$f(b_2 + w_2 e_{t-1}) = \frac{1}{1 + e^{-(b_2 + w_2 e_{t-1})}} = \frac{1}{1 + e^{-(-0,759 - 1,767 e_{t-1})}}$$

$$f(b_3 + w_3 e_{t-1}) = \frac{1}{1 + e^{-(b_3 + w_3 e_{t-1})}} = \frac{1}{1 + e^{-(0,438 - 0,257 e_{t-1})}}$$

**Lampiran 5.** Hasil Proses Pemodelan *Hybrid ARIMAX-Feedforward Neural Network*

(Lanjutan)

c. Pemodelan *Hybrid Feedforward Neural Network* (1-19-1) : (Lanjutan 2)

*Layer* tersembunyi kesatu :

$$f(b_4 + w_4 e_{t-1}) = \frac{1}{1+e^{-(b_4+w_4 e_{t-1})}} = \frac{1}{1+e^{-(-0,483 - 0,420 e_{t-1})}}$$

$$f(b_5 + w_5 e_{t-1}) = \frac{1}{1+e^{-(b_5+w_5 e_{t-1})}} = \frac{1}{1+e^{-(-0,493 + 0,999 e_{t-1})}}$$

$$f(b_6 + w_6 e_{t-1}) = \frac{1}{1+e^{-(b_6+w_6 e_{t-1})}} = \frac{1}{1+e^{-(0,643 + 0,970 e_{t-1})}}$$

$$f(b_7 + w_7 e_{t-1}) = \frac{1}{1+e^{-(b_7+w_7 e_{t-1})}} = \frac{1}{1+e^{-(0,340 - 0,235 e_{t-1})}}$$

$$f(b_8 + w_8 e_{t-1}) = \frac{1}{1+e^{-(b_8+w_8 e_{t-1})}} = \frac{1}{1+e^{-(0,196 + 0,134 e_{t-1})}}$$

$$f(b_9 + w_9 e_{t-1}) = \frac{1}{1+e^{-(b_9+w_9 e_{t-1})}} = \frac{1}{1+e^{-(-0,025 - 0,010 e_{t-1})}}$$

$$f(b_{10} + w_{10} e_{t-1}) = \frac{1}{1+e^{-(b_{10}+w_{10} e_{t-1})}} = \frac{1}{1+e^{-(0,243 - 0,672 e_{t-1})}}$$

$$f(b_{11} + w_{11} e_{t-1}) = \frac{1}{1+e^{-(b_{11}+w_{11} e_{t-1})}} = \frac{1}{1+e^{-(-0,070 + 0,279 e_{t-1})}}$$

$$f(b_{12} + w_{12} e_{t-1}) = \frac{1}{1+e^{-(b_{12}+w_{12} e_{t-1})}} = \frac{1}{1+e^{-(-0,660 - 0,496 e_{t-1})}}$$

$$f(b_{13} + w_{13} e_{t-1}) = \frac{1}{1+e^{-(b_{13}+w_{13} e_{t-1})}} = \frac{1}{1+e^{-(-0,285 - 0,423 e_{t-1})}}$$

$$f(b_{14} + w_{14} e_{t-1}) = \frac{1}{1+e^{-(b_{14}+w_{14} e_{t-1})}} = \frac{1}{1+e^{-(0,063 + 0,455 e_{t-1})}}$$

$$f(b_{15} + w_{15} e_{t-1}) = \frac{1}{1+e^{-(b_{15}+w_{15} e_{t-1})}} = \frac{1}{1+e^{-(-0,186 - 0,131 e_{t-1})}}$$

## Lampiran 5. Hasil Proses Pemodelan *Hybrid ARIMAX-Feedforward Neural Network*

(Lanjutan)

c. Pemodelan *Hybrid Feedforward Neural Network* (1-19-1) : (Lanjutan 2)

*Layer* tersembunyi kesatu :

$$f(b_{16} + w_{16}e_{t-1}) = \frac{1}{1+e^{-(b_{16}+w_{16}e_{t-1})}} = \frac{1}{1+e^{-(-0,166 - 0,082 e_{t-1})}}$$


$$f(b_{17} + w_{17}e_{t-1}) = \frac{1}{1+e^{-(b_{17}+w_{17}e_{t-1})}} = \frac{1}{1+e^{-(-0,205 - 0,261 e_{t-1})}}$$

$$f(b_{18} + w_{18}e_{t-1}) = \frac{1}{1+e^{-(b_{18}+w_{18}e_{t-1})}} = \frac{1}{1+e^{-(0,009 - 0,156 e_{t-1})}}$$

$$f(b_{19} + w_{19}e_{t-1}) = \frac{1}{1+e^{-(b_{19}+w_{19}e_{t-1})}} = \frac{1}{1+e^{-(0,455 - 0,463 e_{t-1})}}$$


## Lampiran 6. Pemilihan Model Terbaik

Model	RMSE-in	RMSEP
ARIMAX	368,273	1411
FFNN	611	<b>214,917</b>
<i>Hybrid ARIMAX-FNN</i>	476,658	500,5




### Lampiran 7. Hasil Peramalan Penjualan Pertamina 12 Periode ke Depan

t	Bulan, Tahun	Penjualan Pertamina
1	Agustus, 2017	12864,13
2	September, 2017	12539,53
3	Oktober, 2017	12663,6
4	Nopember, 2017	12869,27
5	Desember, 2017	12398,75
6	Januari, 2018	12057,26
7	Februari, 2018	11353,21
8	Maret, 2018	12174,99
9	April, 2018	12384,17
10	Mei, 2018	12018
11	Juni, 2018	11851,5
12	Juli, 2018	12957,51



### Lampiran 8. Fits Data Penjualan Pertamina In-Sample dan Out-Sample



## Lampiran 9. Pengujian Terasvirta

```
Nt=as.ts(Nt)
terasvirta.test(Nt)
terasvirta.test(zt)
> library(readxl)
> library(lmtest)
> library(tseries)
> library(forecast)
> library(neuralnet)
> library(nnetpredint)
> ARIMAX<-read_excel("D:/pertamax.xls")
> zt=as.ts(ARIMAX$zt)
> fits=as.ts(ARIMAX$FORECAST[1:91])
> Nt=zt-fits
> Ntrain=as.ts(Nt[2:79])
> Ntest=as.ts(Nt[80:91])
> Nt=as.ts(Nt)
> terasvirta.test(Nt
+ terasvirta.test(zt)
> terasvirta.test(zt)
      Teraesvirta Neural Network Test

data:  zt
X-squared = 7.7511, df = 2, p-value =
0.02074
```

## BIOGRAFI PENULIS



Penulis dilahirkan di Surabaya pada tanggal 7 Januari 1992 dan merupakan putri kedua dari empat bersaudara dari Bapak Drs. M. Slamet Aliwasa. dan Ibu Nur Laily S.Pd., SD. Penulis telah menempuh pendidikan di SD Muhammadiyah 4 Pucang Surabaya (1998-2004), SMP Negeri 6 Surabaya (2004-2007), dan SMA Negeri 9 Surabaya (2007-2010). Penulis kemudian melanjutkan pendidikan ke jenjang Diploma 3 (2010-2013) dan Sarjana (2013-2015) di Perguruan Tinggi (PT) yaitu Institut Teknologi Sepuluh Nopember (ITS) Surabaya Jurusan Statitiska Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA). Pada tahun 2016-2018 penulis diberi kesempatan untuk mendapatkan beasiswa dari ITS untuk melanjutkan pendidikan ke jenjang yang lebih tinggi yaitu jenjang Magister (S2) di Jurusan Statistika, Fakultas Matematika, Komputasi, dan Sains Data (FMKSD) Institut Teknologi Sepuluh Nopember Surabaya. Bagi pembaca yang ingin memberikan kritik, saran, maupun pertanyaan, dapat menghubungi penulis melalui email [uzlifatussyarifah@gmail.com](mailto:uzlifatussyarifah@gmail.com).