



TUGAS AKHIR - SS141501

**PEMODELAN PRODUKSI MINYAK DAN GAS BUMI
PADA *PLATFORM* "MK" DI PT X
MENGUNAKAN METODE ARIMA, *NEURAL NETWORK*,
DAN HIBRIDA ARIMA-*NEURAL NETWORK***

**WINDIA CINDE PRAMESWARI
NRP 1314 105 010**

**Dosen Pembimbing
Dra. Destri Susilaningrum, M.Si
Dr. Suhartono**

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



TUGAS AKHIR - SS141501

**MODELING PRODUCTION OF PETROLEUM
AND NATURAL GAS
IN PLATFORM "MK" AT PT XUSING ARIMA,
NEURAL NETWORK,
AND HYBRID ARIMA-NEURAL NETWORK**

**WINDIA CINDE PRAMESWARI
NRP 1314 105 010**

**Supervisor
Dra. Destri Susilaningrum, M.Si
Dr. Suhartono**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2016**

LEMBAR PENGESAHAN

PEMODELAN PRODUKSI MINYAK DAN GAS BUMI PADA PLATFORM "MK" DI PT X MENGUNAKAN METODE ARIMA, NEURAL NETWORK, DAN HIBRIDA ARIMA-NEURAL NETWORK

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

Program Studi S-1 Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

WINDIA CINDE PRAMESWARI
NRP. 1314 105 010

Disetujui oleh Pembimbing Tugas Akhir :

Dra. Destri Susilaningrum, M. Si

NIP. 19601213 198601 2 001

Dr. Suhartono

NIP. 19710929 199512 1 001

()

()

Mengetahui,

Ketua Jurusan Statistika FMIPA-ITS


Dr. Suhartono

NIP. 19710929 199512 1 001

SURABAYA, JULI 2016

KEMENTERIAN RISET, TEKNOLOGI, DAN PENDIDIKAN TINGGI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

**JURUSAN
STATISTIKA**

**PEMODELAN PRODUKSI MINYAK DAN GAS BUMI
PADA PLATFORM “MK” DI PT “X”
MENGUNAKAN METODE ARIMA,
NEURAL NETWORK, DAN
HIBRIDA ARIMA-NEURAL NETWORK**

Nama Mahasiswa : Windia Cinde Prameswari
NRP : 1314 105 010
Jurusan : Statistika FMIPA-ITS
Dosen Pembimbing: Dra. Destri Susilaningrum, M. Si
Co. Pembimbing : Dr. Suhartono

ABSTRAK

Minyak dan gas bumi dapat diambil secara langsung melalui sumur-sumur yang dibuat, namun sumur-sumur tersebut tidak akan menghasilkan jumlah minyak dan gas bumi yang konstan setiap hari. Ketika kandungan minyak dan gas mulai turun maka yang harus dilakukan adalah memberikan *treatment* terhadap sumur tersebut, sehingga minyak dan gas yang masih terkandung di dasar bumi bisa naik dengan jumlah yang lebih banyak. Tujuan dilakukannya penelitian ini adalah untuk membantu perusahaan dalam menganalisis jumlah produksi minyak dan gas bumi selama periode 14 hari selanjutnya, sehingga dapat diketahui apakah selama periode 14 hari selanjutnya diperlukan *treatment* terhadap sumur. Data yang digunakan adalah jumlah produksi minyak dan gas bumi pada *platform* “MK” pada tahun 2015. Pemodelan jumlah produksi minyak dan gas bumi dilakukan menggunakan tiga metode, yaitu ARIMA, *neural network*, dan Hibrida ARIMA-*neural network*. Hasil yang diperoleh berdasarkan analisis ketiga metode tersebut adalah pada jumlah produksi minyak bumi model terbaik diperoleh dari metode hibrida ARIMA-*neural network*, dengan hasil ramalan yang cenderung sama selama 14 hari yaitu 1961 barel. Sedangkan jumlah produksi gas bumi model terbaik diperoleh dari metode *neural network*, dengan ramalan produksi untuk 14 hari selanjutnya cenderung meningkat.

Kata Kunci : ARIMA, Hibrida ARIMA-Neural Network, Minyak dan Gas Bumi, Neural Network

“Halaman ini sengaja dikosongkan”

**MODELING PRODUCTION OF PETROLEUM AND
NATURAL GAS
IN PLATFORM "MK" AT PT X
USING ARIMA, NEURAL NETWORK,
AND HYBRID ARIMA-NEURAL NETWORK**

Name of Student : Windia Cinde Prameswari
NRP : 1314 105 010
Department : Statistics
Supervisor : Dra. Destri Susilaningrum, M. Si
Co. Supervisor : Dr. Suhartono

ABSTRACT

Petroleum and natural gas can be taken directly through the wells that were made, but the wells will not produce the amount of oil and gas is a constant every day. When petroleum and natural gas begin to fall then that should be done is to provide treatment to those wells, so that oil and gas are still contained in the bottom of the earth could rise with higher numbers. The purpose of this study is to assist companies in analyzing the amount of petroleum and natural gas production over the next 14 day period, so it can be known whether during the period of 14 days is required subsequent treatment of the wells. The data used is the number of petroleum and natural gas production on the platform "MK" in 2015. Modelling the number of oil and gas production is done using three methods, namely ARIMA, Neural Network, and Hybrid ARIMA-NN. The results obtained by the analysis of these three methods is the best model of petroleum production is obtained from a hybrid method ARIMA-NN, with production that tends same forecast for 14 days, about 1961 barrel. Meanwhile, natural gas production is obtained from the best models Neural Network methods, with production forecast production for the next 14 days is likely to increase.

Keyword : *ARIMA, Hybrid ARIMA-Neural Network, Neural Network, Petroleum and Natural Gas*

“Halaman ini sengaja dikosongkan”

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
DAFTAR LAMPIRAN	xix
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	4
1.3 Tujuan Penelitian	4
1.4 Manfaat Hasil Penelitian.....	4
1.5 Batasan Masalah	5
BAB II TINJAUAN PUSTAKA	7
2.1 Statistika Deskriptif.....	7
2.2 <i>Time Series</i> ARIMA.....	8
2.2.1 Identifikasi Model ARIMA.....	9
2.2.2 Model ARIMA.....	10
2.2.3 Estimasi Parameter.....	13
2.2.4 Uji Signifikansi Parameter.....	14
2.2.5 Uji Kesesuaian Model.....	15
2.2.6 Deteksi <i>Outlier</i>	17
2.2.7 Pemilihan Model Terbaik	17
2.3 Uji Linieritas	18
2.4 <i>Neural Network</i>	18
2.4 Hibrida ARIMA-NN	23
2.5 Minyak dan Gas Bumi	24
BAB III METODOLOGI PENELITIAN	27
3.1 Sumber Data.....	27
3.2 Langkah Analisis.....	27

BAB IV ANALISIS DAN PEMBAHASAN	35
4.1 Deskriptif Produksi Minyak dan Gas Bumi	35
4.2 Pemodelan Produksi Minyak Bumi	37
4.2.1 Pemodelan Produksi Minyak Bumi Dengan ARIMA.....	38
4.2.2 Pemodelan Produksi Minyak Bumi Dengan <i>Neural Network</i>	49
4.2.3 Pemodelan Produksi Minyak Bumi Dengan Hibrida ARIMA- <i>Neural Network</i>	52
4.3 Pemodelan Produksi Gas Bumi.....	56
4.3.1 Pemodelan Produksi Gas Bumi Dengan ARIMA.....	56
4.3.2 Pemodelan Produksi Gas Bumi Dengan <i>Neural Network</i>	67
4.3.3 Pemodelan Produksi Gas Bumi Dengan Hibrida ARIMA- <i>Neural Network</i>	69
BAB V KESIMPULAN DAN SARAN	73
5.1 Kesimpulan	73
5.2 Saran.....	73
DAFTAR PUSTAKA	75
LAMPIRAN	79
BIODATA PENULIS	

DAFTAR GAMBAR

Gambar 2.1 Arsitektur <i>Backpropagation</i>	20
Gambar 3.1 Diagram Alir Langkah Analisis	30
Gambar 3.2 Diagram Alir Metode ARIMA.....	31
Gambar 3.3 Diagram Alir Metode <i>Neural Network</i>	32
Gambar 3.4 Diagram Alir Hibrida ARIMA-NN.....	33
Gambar 4.1 Boxplot Produksi Minyak Bumi	36
Gambar 4.2 Boxplot Produksi Gas Bumi	37
Gambar 4.3 Time Series Plot Produksi Minyak Bumi	38
Gambar 4.4 Transformasi Box-cox Produksi Minyak Bumi ...	39
Gambar 4.5 Plot ACF Produksi Minyak Bumi	40
Gambar 4.6 Plot ACF Produksi Minyak Bumi Setelah <i>Differencing</i>	41
Gambar 4.7 Plot ACF Produksi Minyak Bumi Setelah <i>Differencing</i>	41
Gambar 4.8 Arsitektur <i>Neural Network</i> 5 Neuron Data Jumlah Produksi Minyak Bumi	51
Gambar 4.9 Plot Akurasi <i>In Sample</i> Data Jumlah Produksi Minyak Bumi	55
Gambar 4.10 Plot Akurasi <i>Out Sample</i> Data Jumlah Produksi Minyak Bumi	55
Gambar 4.11 <i>Time Series</i> Plot Gas Bumi	57
Gambar 4.12 Transformasi Box-Cox Gas Bumi.....	57
Gambar 4.13 Plot ACF Gas Bumi	58
Gambar 4.14 Plot ACF Gas Bumi Sudah Stasioner	59
Gambar 4.15 Plot PACF Gas Bumi Sudah Stasioner	59
Gambar 4.16 Arsitektur <i>Neural Network</i> 2 Neuron Produksi Bumi.....	68
Gambar 4.17 Plot Akurasi <i>In Sample</i> Data Jumlah Produksi Gas Bumi.....	70
Gambar 4.18 Plot Akurasi <i>Out Sample</i> Data Jumlah Produksi Gas Bumi	71
Gambar 4.19 Plot Akurasi <i>Out Sample</i> Data Jumlah Produksi Gas Bumi	71

“Halaman ini sengaja dikosongkan”

DAFTAR TABEL

Tabel 2.1	Transformasi <i>Box-Cox</i>	9
Tabel 2.2	Identifikasi Model <i>Time Series</i>	9
Tabel 3.1	Struktur Data Penelitian.....	27
Tabel 4.1	Deskriptif Jumlah Produksi Minyak dan Gas Bumi	33
Tabel 4.2	Uji Signifikansi Parameter Data Produksi Minyak Bumi	42
Tabel 4.3	Uji Kesesuaian Model Data Produksi Minyak Bumi	43
Tabel 4.4	Uji Signifikansi Parameter ARIMA (0,1,1) Deteksi Outlier Data Produksi Minyak Bumi	43
Tabel 4.5	Uji Kesesuaian Model ARIMA (0,1,1) Deteksi Outlier Data Produksi Minyak Bumi.....	45
Tabel 4.6	Uji Signifikansi Parameter ARIMA (0,1,2) Deteksi Outlier Data Produksi Minyak Bumi	46
Tabel 4.7	Uji Kesesuaian Model ARIMA (0,1,2) Deteksi Outlier Data Produksi Minyak Bumi.....	47
Tabel 4.8	Pemilihan Model Terbaik Data Produksi Minyak Bumi	48
Tabel 4.9	Pemodelan Metode <i>Neural Network</i> Data Jumlah Produksi Minyak Bumi	50
Tabel 4.10	Pemodelan Metode Hibrida Data Produksi Minyak Bumi.....	52
Tabel 4.11	Perbandingan Hasil Metode Terbaik Data Produksi Minyak Bumi	54
Tabel 4.12	Ramalan Produksi Minyak Bumi.....	56
Tabel 4.13	Uji Signifikansi Parameter Data Produksi Gas Bumi	60
Tabel 4.14	Uji Kesesuaian Model Data Produksi Gas Bumi	61

Tabel 4.15 Uji Signifikansi Parameter Model ARIMA (0,1,1) Deteksi <i>Outlier</i> Data Produksi Gas Bumi	61
Tabel 4.16 Uji Kesesuaian Model ARIMA (0,1,1) Deteksi <i>Outlier</i> Data Produksi Gas Bumi	63
Tabel 4.17 Uji Signifikansi Parameter Model ARIMA (1,1,1) Deteksi <i>Outlier</i> Data Produksi Gas Bumi	63
Tabel 4.18 Uji Kesesuaian Model ARIMA (1,1,1) Deteksi <i>Outlier</i> Data Produksi Gas Bumi	65
Tabel 4.19 Pemilihan Model Terbaik Data Produksi Gas Bumi	66
Tabel 4.20 Pemodelan NN Data Produksi Gas Bumi	67
Tabel 4.21 Pemodelan Hibrida ARIMA- <i>Neural Network</i> Produksi Gas Bumi.....	69
Tabel 4.22 Perbandingan Model Data Produksi Gas Bumi	70
Tabel 4.23 Ramalan Produksi Gas Bumi.....	71

DAFTAR LAMPIRAN

Lampiran 1	Data Jumlah Produksi Minyak Bumi Tahun 2015	79
Lampiran 2	Data Jumlah Produksi Gas Bumi Tahun 2015	80
Lampiran 3	Nilai Box Plot Data Jumlah Produksi Minyak Bumi Tahun 2015	81
Lampiran 4	Nilai Box Plot Data Jumlah Produksi Gas Bumi Tahun 2015	81
Lampiran 5	Nilai ACF Data Produksi Minyak Bumi Setelah <i>Differencing</i>	82
Lampiran 6	Nilai PACF Data Produksi Minyak Bumi Setelah <i>Differencing</i>	83
Lampiran 7	Residual ARIMA Jumlah Produksi Minyak Bumi Tahun 2015	84
Lampiran 8	Nilai ACF Data Produksi Minyak Bumi Setelah <i>Differencing</i>	85
Lampiran 9	Nilai PACF Data Produksi Minyak Bumi Setelah <i>Differencing</i>	86
Lampiran 10	Residual ARIMA Jumlah Produksi Gas Bumi Tahun 2015	87
Lampiran 11	<i>Output</i> ARIMA Jumlah Produksi Minyak Bumi	88
Lampiran 12	<i>Output</i> ARIMA Jumlah Produksi Gas Bumi	90
Lampiran 13	<i>Output Neural Network</i> Jumlah Produksi Minyak Bumi	92
Lampiran 14	<i>Output Neural Network</i> Jumlah Produksi Gas Bumi	94
Lampiran 15	<i>Output</i> Hibrida ARIMA- <i>Neural Network</i> Jumlah Produksi Minyak Bumi	95
Lampiran 16	<i>Output</i> Hibrida ARIMA- <i>Neural Network</i> Jumlah Produksi Gas Bumi	97

“Halaman ini sengaja dikosongkan”

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sumber daya alam yang tidak dapat diperbaharui adalah sumber daya alam yang sangat sulit dihasilkan kembali setelah habis digunakan. Sumber daya alam jenis ini akan habis jika digunakan secara terus-menerus. Manusia tidak dapat memperbanyak lagi dan jumlah dari sumber daya alam ini sangat terbatas, sehingga harus dimanfaatkan sebaik-baiknya. Salah satu contoh dari sumber daya alam yang tidak dapat diperbaharui adalah minyak dan gas bumi (Utami, 2013).

Minyak dan gas bumi adalah campuran senyawa hidrokarbon yang tersusun dari sebagian besar karbon dan hidrogen dengan sedikit belerang, nitrogen, dan unsur-unsur lainnya. Minyak dan gas bumi diduga secara tidak langsung berasal dari sisa-sisa organisme hidup. Ada tiga faktor utama dalam pembentukan minyak dan gas bumi, yaitu yang pertama adalah bebatuan asal yang secara geologis memungkinkan terjadinya pembentukan minyak bumi. Kedua, adanya perpindahan hidrokarbon dari bebatuan asal menuju ke bebatuan reservoir. Ketiga, adanya jebakan geologis. Struktur geologis kulit bumi yang tidak teratur bentuknya, akibat pergerakan dari bumi sendiri (Samperuru, 2007).

Di Indonesia cadangan minyak bumi yang tersisa saat ini sebanyak 3,7 miliar barel, sedangkan konsumsi minyak dunia per harinya sebesar 1.084.000 barel dan diperkirakan akan habis 10 sampai 11 tahun mendatang (Ansyari, 2015). Proses pengolahan minyak bumi memakan waktu yang lama, hingga menjadi minyak yang dapat digunakan bagi kehidupan sehari-hari. Hal yang penting dilakukan untuk dapat mengambil kandungan minyak yang ada di dasar bumi adalah dengan melakukan pengeboran sumur. Dalam proses penyedotan minyak bumi, sebuah sumur tidak bisa hanya menyedot minyak saja. Banyak kandungan lain dari dasar bumi yang juga terambil, contohnya adalah gas yang selanjutnya

gas ini disebut dengan gas bumi. Lokasi sumur-sumur minyak ini didapatkan setelah melalui proses studi geologi, analisis sedimen, karakter, struktur sumber, dan berbagai macam studi lainnya. Setelah itu minyak bumi akan diproses dan dipisahkan hasilnya berdasarkan titik didih, sehingga menghasilkan berbagai macam bahan bakar (Ardiansyah, 2014). Kedalaman dan tekanan sumur sangat berpengaruh terhadap jumlah produksi minyak bumi yang dihasilkan. Selain itu siklus hidup sumur juga penting diperhatikan untuk mendapatkan minyak bumi yang banyak. Sebuah sumur tidak akan terus-menerus menghasilkan minyak bumi yang berlimpah secara konstan. Akan ada saatnya dimana sumur mulai melemah untuk menyedot kandungan minyak dan gas yang ada di dasar bumi. Ketika kandungan minyak dan gas bumi yang diambil mulai turun maka hal yang harus dilakukan adalah memberikan *treatment* terhadap sumur tersebut, sehingga minyak dan gas yang masih terkandung di dasar bumi tersebut bisa naik. Dalam melakukan *treatment* terhadap sumur, dibutuhkan persiapan-persiapan khusus sebelumnya. Agar perusahaan dapat merencanakan dilakukan *treatment* pada sumur tersebut, maka perlu diketahui jumlah produksi minyak dan gas bumi untuk waktu selanjutnya. Ketika produksi minyak dan gas mengalami penurunan yang tidak sedikit, maka pada saat itu dibutuhkan *treatment* untuk sumur tersebut (Samperuru,2007).

Salah satu perusahaan ternama di Indonesia yang bekerja di bidang perminyakan memiliki banyak sumur untuk mengambil kandungan minyak dan gas yang ada di dasar bumi. Sumur-sumur tersebut dikelompokkan berdasarkan wilayah yang saling berdekatan yang biasa disebut dengan platform. Dari beberapa *platform* yang berdekatan tersebut, minyak dan gas bumi selanjutnya dikirim ke terminal pusat untuk diproses. Penelitian ini menggunakan data jumlah produksi minyak dan gas bumi yang berasal dari sumur-sumur di wilayah NBI. Dalam wilayah NBI terdapat 4 *platform*, namun pada penelitian ini hanya akan digunakan 1 *platform* saja yaitu *platform* "MK".

Tujuan dari penelitian ini adalah untuk membantu perusahaan menganalisis jumlah produksi minyak dan gas selama periode 14 hari selanjutnya, sehingga dapat diketahui selama periode 14 hari selanjutnya perlu dilakukan *treatment* terhadap sumur atau tidak. Agar dapat mencapai tujuan tersebut, metode yang sering digunakan untuk meramalkan adalah ARIMA. Model ARIMA adalah model yang mengabaikan variabel prediktor dalam penyusunan model ramalan dan model diasumsikan sebagai fungsi linier. Dengan adanya pendekatan model ARIMA tersebut, diharapkan dapat meningkatkan akurasi nilai ramalan yang dihasilkan. Namun pada kenyataannya tidak sedikit model *time series* mengikuti fungsi linier. Ketika model linier menghasilkan tingkat akurasi peramalan yang relatif kecil dan kesalahan prediksi yang besar, kemungkinan model nonlinier mampu menjelaskan dan meramalkan data *time series* dengan lebih baik (Zhang, 2003). Salah satu metode yang dapat digunakan untuk memodelkan data *time series* adalah *neural network*. *Neural Network* (NN) merupakan salah satu contoh model nonlinier yang mempunyai bentuk fungsional fleksibel dan mengandung beberapa parameter yang tidak dapat diinterpretasikan seperti model parametrik (Suhartono, 2007).

Penelitian tentang minyak mentah sebelumnya pernah dilakukan oleh Adnyana (2013) dengan judul Penerapan Bootstrap Pada *Neural Network* untuk Peramalan Produksi Minyak Mentah di Indonesia. Penelitian tersebut meramalkan produksi minyak mentah dengan membandingkan metode ARIMA, *neural network*, dan *neural network* dengan bootstrap. Hasil yang diperoleh adalah model yang paling baik menggambarkan data dan berdasarkan nilai MSE yaitu model *neural network* sederhana. Selain Adnyana, penelitian sejenis pernah dilakukan oleh Kusumaningrum (2012) dengan judul Peramalan Kebutuhan Bahan Bakar Premium di Depot Ampean Dengan Metode Hibrida ARIMA – NN Untuk Optimasi Persediaan. Penelitian tersebut membandingkan antara model ARIMA – NN dengan model hibrida ARIMA – NN. Hasil yang diperoleh dari penelitian tersebut adalah model hibrida

menghasilkan hasil peramalan yang lebih akurat dibandingkan model tunggal.

1.2 Perumusan Masalah

Berdasarkan latar belakang tersebut, maka permasalahan yang diambil dalam penelitian ini adalah sebagai berikut.

1. Bagaimana deskriptif dari jumlah produksi minyak dan gas bumi pada *platform* “MK” di PT “X”?
2. Bagaimana hasil ramalan jumlah produksi minyak bumi pada *platform* “MK” di PT X selama 14 hari selanjutnya?
3. Bagaimana hasil ramalan jumlah produksi gas bumi pada *platform* “MK” di PT X selama 14 hari selanjutnya?

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai berdasarkan permasalahan dalam penelitian ini adalah sebagai berikut.

1. Mendeskripsikan karakteristik produksi minyak dan gas bumi pada *platform* “MK” di PT “X”.
2. Meramalkan jumlah produksi minyak bumi pada *platform* “MK” di PT X selama 14 hari selanjutnya.
3. Meramalkan jumlah produksi gas bumi pada *platform* “MK” di PT X selama 14 hari selanjutnya.

1.4 Manfaat Hasil Penelitian

Penelitian ini diharapkan menghasilkan informasi yang akurat mengenai hasil ramalan tentang jumlah produksi minyak dan gas pada *platform* “MK” di PT “X”, sehingga dapat memberikan manfaat untuk beberapa pihak di antaranya.

1. Bagi Penulis
Penulis dapat mengaplikasikan ilmu statistika terhadap kehidupan sehari-hari khususnya dalam bidang perminyakan.
2. Bagi Perusahaan
Memberikan informasi mengenai jumlah produksi minyak dan gas bumi selama periode 14 hari selanjutnya, sehingga

perusahaan dapat mengetahui selama 14 hari selanjutnya diperlukan *treatment* terhadap sumur atau tidak.

1.5 Batasan Masalah

Batasan masalah yang digunakan dalam penelitian ini adalah data jumlah produksi minyak dan gas bumi dari *platform* “MK” pada wilayah NBI di PT “X” . Selain itu metode *neural network* yang digunakan dalam penelitian ini adalah *feed forward neural network*. Pada uji kesesuaian model ARIMA residual diasumsikan telah identik.

“Halaman ini sengaja dikosongkan”

BAB II TINJAUAN PUSTAKA

Pada bagian ini dijelaskan teori yang berkaitan dengan produksi minyak dan gas bumi. Serta dijelaskan pula analisis yang digunakan dalam penelitian ini antara lain adalah statistika deskriptif, ARIMA, *Neural Network*, Hibrida ARIMA-*neural network*, dan uji linieritas data (uji *Terasvirta*).

2.1 Statistika Deskriptif

Statistika deskriptif adalah metode-metode yang berkaitan dengan pengumpulan dan penyajian suatu gugus data sehingga memberikan informasi yang berguna (Walpole, 1995). Statistika deskriptif berbeda dengan statistika inferensial, pada statistika deskriptif hanya dapat mendeskripsikan dan menggambarkan data populasi yang telah terkumpul tanpa membuat kesimpulan yang berlaku umum. Sedangkan statistika inferensial adalah jenis statistik yang menganalisis data sampel, dan membuat kesimpulan yang digeneralisasi pada populasi. Dalam penelitian ini metode statistika deskriptif yang akan digunakan adalah boxplot, mean, minimum, maximum, dan varians.

Boxplot yang juga dikenal dengan istilah *box and whisker* merupakan salah satu alat dalam statistika deskriptif untuk menggambarkan data numerik melalui 5 ukuran, yaitu nilai observasi terkecil, kuartil pertama (Q1), median (Q2), kuartil 3 (Q3), dan nilai observasi terbesar. Selain itu boxplot juga dapat menunjukkan nilai *outlier* dalam observasi. Rumus dari median ditunjukkan dalam Persamaan (2.1), sedangkan rumus dari kuartil ditunjukkan pada Persamaan (2.2).

$$Me = x_{\left(\frac{n+1}{2}\right)}, \text{ untuk data ganjil}$$

atau

(2.1)

$$Me = \frac{1}{2} \left(x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n+1}{2}\right)} \right), \text{ untuk data genap}$$

$$\text{Data ganjil: } Q_i = X_{\frac{i(n+1)}{4}}$$

atau

(2.2)

$$\text{Data genap} \begin{cases} Q_1 = X_{\frac{(n+2)}{4}} \\ Q_3 = X_{\frac{(3n+2)}{4}} \end{cases}$$

2.2 Time Series ARIMA

Time series merupakan urutan observasi berdasarkan pada interval waktu, dengan tujuan untuk memahami dan memberikan gambaran dalam membuat suatu mekanisme, peramalan nilai masa depan dan optimalisasi sistem kontrol (Wei, 2006). Rangkaian data pengamatan *time series* dinyatakan sebagai variabel Z_t dengan t adalah indeks waktu yang menggambarkan urutan pengamatan. Terdapat beberapa metode yang dapat digunakan dalam menganalisis data *time series*, penelitian ini menggunakan metode ARIMA. Dalam menganalisis suatu data menggunakan ARIMA yang harus dilakukan terlebih dahulu adalah mengidentifikasi stasioneritas data, baik dalam mean dan varians. Suatu data *time series* dapat dikatakan telah stasioner, apabila mean dan varians dari data tersebut tidak ada perubahan sistematis. Ketika data tersebut belum stasioner, maka perlu dilakukan sebuah transformasi untuk menanggulangnya. Tidak stasionernya data terhadap mean dapat diatasi dengan melakukan *differencing*. *Differencing* pada orde ke- d adalah sebagai berikut.

$$W_t = (1 - B)^d Z_t \quad (2.3)$$

Sedangkan, ketika data tidak stasioner dalam *variens* maka dapat ditransformasi dengan menggunakan transformasi *Box-Cox*. Persamaan (2.4) berikut merupakan persamaan umum dari transformasi *Box-Cox*.

$$T(Z_t) = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda}, \lambda \neq 0 \\ \lim_{\lambda \rightarrow 0} \frac{Z_t^\lambda - 1}{\lambda}, \lambda = 0 \end{cases} \quad (2.4)$$

Nilai λ yang digunakan dalam persamaan tersebut merupakan parameter transformasi yang digunakan dalam transformasi *Box-Cox*. Tabel 2.1 merupakan penjelasan parameter transformasi *Box-Cox*.

Nilai Estimasi (λ)	Transformasi
-1	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0	$\ln(Z_t)$
0,5	$\sqrt{Z_t}$
1	Z_t

(Wei, 2006).

2.2.1 Identifikasi Model ARIMA

Identifikasi awal untuk membentuk model ARIMA yang tepat dapat dilakukan dengan memperhatikan pola plot ACF dan PACF. Tabel 2.2 menjelaskan ciri-ciri model *time series* yang dilihat berdasarkan plot ACF dan PACF.

Model	ACF	PACF
AR (p)	<i>Dies Down</i>	<i>Cuts for after lag p</i>
MA (q)	<i>Cuts for after lag q</i>	<i>Dies Down</i>
ARMA (p,q)	<i>Dies down</i>	<i>Dies Down</i>

(Bowerman dan O'Connell, 1993).

a. *Autocorrelation Function (ACF)*

Autocorrelation Function (ACF) adalah korelasi antara Z_t dengan Z_{t+k} yang menunjukkan adanya keterkaitan dependensi linier. Rumus umum dari ACF dapat dilihat pada Persamaan (2.5).

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, k = 0, 1, 2, \dots \quad (2.5)$$

Dimana \bar{Z} merupakan nilai rata-rata dari data *time series*

$$\left(\bar{Z} = \frac{\sum_{t=1}^n Z_t}{n} \right)$$

(Wei, 2006).

b. *Partial Autocorrelation Function (PACF)*

Partial Autocorrelation Function (PACF) digunakan untuk mengetahui korelasi antara Z_t dengan Z_{t+k} setelah pengaruh dari dependensi linier $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k}$ dihilangkan. Nilai PACF disimbolkan $\hat{\phi}_{kk}$ dengan $\hat{\phi}_{11} = \rho_1$, nilai $\hat{\phi}_{kk}$ yang lain dapat dihitung dengan Persamaan (2.6) dan (2.7) berikut.

$$\hat{\phi}_{k+1, k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.6)$$

dan

$$\hat{\phi}_{k=1, j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1, k+1} \hat{\phi}_{k, k+1-j}, j = 1, 2, \dots, k \quad (2.7)$$

(Wei, 2006).

2.2.2 Model ARIMA

Model ARIMA merupakan gabungan antara model AR dan MA serta *differencing* orde d. Model ARIMA dapat

digunakan pada data musiman maupun non musiman. Model ARIMA dibagi menjadi 3 kelompok, yaitu sebagai berikut.

1. *Autoregressive* (AR)

Model *autoregressive* merupakan model yang menunjukkan nilai observasi Z_t bergantung pada Z_{t+1} . Bentuk umum dari model *autoregressive* pada orde ke- p atau AR(p) adalah sebagai berikut.

$$(1 - \phi_1 B - \dots - \phi_p B^p) \dot{Z}_t = a_t \quad (2.8)$$

atau

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t \quad (2.9)$$

dimana,

$$\dot{Z}_t : Z_t - \mu$$

ϕ_i : parameter *autoregressive* dengan $i = 1, 2, \dots, p$

a_t : nilai kesalahan pada saat t

2. *Moving Average* (MA)

Model *moving average* dikenal juga sebagai model rata-rata bergerak. Model ini memperlihatkan nilai observasi Z_t bergantung pada nilai kesalahan a_t dan juga nilai kesalahan sebelumnya a_{t-1} . Bentuk umum dari model *moving average* pada orde ke- q atau MA(q) adalah sebagai berikut.

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.10)$$

atau

$$\dot{Z}_t = \theta(B) a_t \quad (2.11)$$

dimana,

$$\dot{Z}_t : Z_t - \mu$$

θ_q : parameter *moving average*

a_t : nilai kesalahan pada saat t sampai q

3. *Mixed Autoregressive Moving Average (ARMA)*

Model ARMA merupakan model campuran dari model AR dan MA tanpa proses *differencing*. Bentuk umum dari model ARMA dengan orde ke-p,q adalah sebagai berikut.

$$\phi_p(B)\dot{Z}_t = \theta_q(B)a_t \quad (2.12)$$

atau

$$\begin{aligned} \dot{Z}_t = & \phi_1 Z_{t-1} - \phi_2 Z_{t-2} - \dots - \phi_p Z_{t-p} - \\ & \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} + a_t \end{aligned} \quad (2.13)$$

dimana,

\dot{Z}_t : $Z_t - \mu$

(p,q) : orde AR (p), orde MA (q)

a_t : nilai kesalahan pada saat t

4. *Autoregressive Integrated Moving Average (ARIMA)*

Model ARIMA merupakan penggabungan antara model *autoregressive* (AR) dan *moving average* (MA) serta proses *differencing* dengan orde ke-d untuk data non musiman, dan orde ke-D untuk data musiman terhadap data yang berkala. Secara umum, model ARIMA non musiman dapat dituliskan sebagai ARIMA (p,d,q) dengan model matematis sebagai berikut.

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)a_t \quad (2.14)$$

dimana,

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p) \quad (2.15)$$

dan

$$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q) \quad (2.16)$$

Untuk data yang mengandung pola musiman dengan *differencing* orde ke-D dapat dinotasikan sebagai ARIMA (P,D,Q)^s. Secara umum model ARIMA multiplikasi musiman dapat ditulis pada persamaan sebagai berikut.

$$\Phi_P(B^S)\phi_P(B)(1-B)^d(1-B^S)^D\dot{Z}_t = \theta_q(B)\Theta_Q(B^S)a_t \quad (2.17)$$

dimana,

$$\dot{Z}_t = \begin{cases} Z_t - \mu, & \text{jika } d = D = 0, \\ Z_t, & \text{yang lain} \end{cases} \quad (2.18)$$

$$\Phi_P(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS} \quad (2.19)$$

dan

$$\Theta_Q(B^S) = 1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS} \quad (2.20)$$

(Makridarkis, Wheelwright, dan McGee, 1999).

2.2.3 Estimasi Parameter

Dalam melakukan estimasi parameter untuk model ARIMA terdapat beberapa metode yang dapat digunakan, salah satu metode estimasi parameter menurut Jenkins & Reinsel (2008) adalah estimasi *conditional least square*. Estimasi *conditional least square* didapatkan dengan meminimumkan fungsi *conditional sum-of-squares*. Fungsi *conditional sum-of-squares* menurut Cryer & Chan (2008) sebagai berikut:

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

Anggap persamaan $\partial S / \partial \mu = 0$ maka

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

menyederhanakan μ

$$\mu = \frac{1}{(n-1)(1-\phi)} \left[\sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1} \right] \quad (2.23)$$

dengan memperhatikan ϕ Persamaan (2.23) dapat dituliskan sebagai berikut.

$$\hat{\mu} \approx \frac{1}{1-\phi} (\bar{Z} - \phi \bar{Z}) = \bar{Z} \quad (2.24)$$

Dimana $\hat{\mu} = \bar{Z}$ maka minimalisasi dari $S(\phi, \bar{Z})$ dengan memperhatikan ϕ diperoleh

$$\frac{\partial S(\phi, \bar{Z})}{\partial \phi} = \sum_{t=2}^n 2[(Z_t - \bar{Z}) - \phi(Z_{t-1} - \bar{Z})](Z_{t-1} - \bar{Z}) \quad (2.25)$$

Persamaan (2.25) kemudian di samadengankan nol dan penyelesaian untuk ϕ sebagai berikut:

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \quad (2.26)$$

2.2.4 Uji Signifikansi Parameter

Uji signifikansi parameter dilakukan untuk mengetahui apakah parameter model ARIMA yang telah diperoleh signifikan atau tidak. Berikut merupakan hipotesis yang akan diuji, dengan β merupakan simbol parameter untuk ϕ (AR) atau θ (MA) sebagai berikut.

Hipotesis :

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

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

Statistik uji :

$$t = \frac{\hat{\beta}}{SE(\hat{\beta})} \quad (2.27)$$

dimana,

$\hat{\beta}$: estimasi setiap parameter ϕ_1 atau θ_1 pada model
ARIMA

$SE(\hat{\beta})$: standar residual dari setiap estimasi $\hat{\beta}$

Daerah kritis :

Tolak H_0 jika $|t| > t_{\alpha/2, n-p}$

2.2.5 Uji Kesesuaian Model

Uji kesesuaian model digunakan untuk melihat apakah parameter yang digunakan dalam model sudah sesuai atau belum atau dengan kata lain adalah pengujian asumsi residual. Ada beberapa pengujian dalam uji kesesuaian model, yaitu uji residual *white noise* dan uji residual berdistribusi normal.

1. Uji residual *white noise*

Residual dari suatu model dikatakan *white noise* apabila antar residual tidak ada hubungan dan varians homogen, dengan kata lain adalah independen dan identik. Salah satu metode yang dapat digunakan untuk menguji residual independen adalah uji Ljung-Box. Dimana hipotesis dan statistik uji yang digunakan untuk menguji residual independen dapat dituliskan sebagai berikut.

Hipotesis :

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

$$H_1 : \text{minimal ada satu } \rho_j \neq 0, \text{ untuk } j = 1, 2, \dots, k$$

Statistik uji :

$$Q = n(n+2) \sum_{j=1}^k \frac{\hat{\rho}_j^2}{n-j} \quad (2.28)$$

dimana,

n : banyaknya pengamatan

$\hat{\rho}_j$: ACF residual pada lag ke- j

k : maksimum lag

Daerah kritis :

Tolak H_0 jika nilai $Q > \chi_{(1-\alpha); K-p-q}^2$, dengan p adalah orde

AR dan q adalah orde MA.

Terdapat beberapa metode untuk menguji residual identik, salah satunya menggunakan uji *Lagrange Multiplier*. Model dari residual identik dapat dilihat sebagai berikut.

$$\hat{a}_t = \alpha_0 + \alpha_1 \hat{a}_{t-1}^2 + \alpha_2 \hat{a}_{t-2}^2 + \dots + \alpha_s \hat{a}_{t-s}^2 + \varepsilon_t \quad (2.29)$$

Hipotesis dan statistik uji yang digunakan dalam pengujian residual identik dapat dituliskan sebagai berikut.

Hipotesis :

$$H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_s = 0$$

H_1 : minimal ada satu $\alpha_i \neq 0$, untuk $i = 1, 2, \dots, s$

Statistik uji :

$$\chi_{hitung}^2 = (n - s)R^2 \quad (2.30)$$

Dimana R^2 adalah koefisien determinasi dari Persamaan 2.29.

Daerah kritis :

$$\text{Tolak } H_0 \text{ jika } \chi_{hitung}^2 > \chi_{\alpha, s}^2$$

(Wei, 2006).

2. Uji Distribusi Normal

Pengujian residual berdistribusi normal dapat dilakukan dengan menggunakan Kolmogorov Smirnov Test.

Hipotesis :

H_0 : $F(a_t) = F_0(a_t)$ (data berdistribusi normal)

H_1 : $F(a_t) \neq F_0(a_t)$ (data tidak berdistribusi normal)

Statistik uji :

$$D = \text{Sup} |S(a_t) - F_0(a_t)| \quad (2.31)$$

Dimana $S(a_t)$ adalah fungsi peluang kumulatif yang dihitung dari data sampel. $F_0(a_t)$ merupakan fungsi peluang kumulatif dari distribusi normal, Sup sebagai nilai supremum untuk semua a_t dari $|S(a_t) - F_0(a_t)|$.

Daerah kritis :

Tolak H_0 jika $D > D_{(1-\alpha), n}$, dengan nilai n adalah ukuran sampel.

(Daniel, 1989).

2.2.6 Deteksi Outlier

Beberapa jenis *outlier* yang diketahui yaitu *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan

Temporary Change (TC). Salah satu cara dalam mengatasi adanya *outlier* adalah melakukan deteksi *outlier* (Wei, 2006). Model umum dengan k *outlier* adalah sebagai berikut.

$$Z_t = \sum_{j=1}^k \omega_j v_j(B) I_t^{(T_j)} + X_t \quad (2.32)$$

dimana,

$$X_t = \frac{\theta(B)}{\phi(B)} a_t$$

$$v_j(B) = \begin{cases} 1, & \text{untuk AO} \\ \frac{\theta(B)}{\phi(B)}, & \text{untuk IO} \end{cases}$$

$$I_t^{(T_i)} = \begin{cases} 1, & t = T_i \\ 0, & t \neq T_i \end{cases}$$

Bentuk umum dari *Additive Outlier* (AO) dan *Level Shift* (LS) adalah sebagai berikut.

$$AO : Z_t = X_t + \omega_A I_t^{(T)}$$

$$LS : Z_t = X_t + \frac{1}{(1-B)} \omega_L I_t^{(T)}$$

2.2.7 Pemilihan Model Terbaik

Pemilihan model terbaik dapat dilakukan berdasarkan beberapa kriteria, salah satu kriteria yang dijadikan sebagai pemilihan model terbaik adalah nilai *Root Mean Square Error* (RMSE) pada data *out sample*. Rumus umum dari RMSE *out sample* ditunjukkan pada Persamaan (2.33).

$$RMSE = \sqrt{\frac{1}{M} \sum_{l=1}^M (Z_{n+l} - Z_n(l))^2} \quad (2.33)$$

dimana,

M : jumlah ramalan

Z_{n+l} : data ramalan *out sample* ke-l

n : jumlah observasi *in sample* dari data *time series* (Wei, 2006).

2.3 Uji Linieritas

Sebelum menerapkan model non linier terlebih dahulu dilakukan uji non linieritas pada data *time series*, hal ini dilakukan untuk memastikan bahwa metode yang digunakan sudah sesuai dengan datanya. Uji linieritas yang digunakan dalam penelitian ini adalah uji terasvirta dengan pendekatan ekspansi Taylor pada tipe LM (*Langrange Multiplier*).

Hipotesis :

$H_0 : f(X)$ adalah fungsi linier dalam X (model linier)

$H_1 : f(X)$ adalah fungsi non linier dalam X (model non linier)

Prosedur untuk mendapatkan uji F adalah sebagai berikut.

1. Regresikan y_t pada y_{t-1}, \dots, y_{t-p} , hitung residual \hat{a}_t dan jumlah kuadrat residual $SSR_0 = \sum \hat{a}_t^2$
2. Regresikan \hat{a}_t pada 1, y_{t-1}, \dots, y_{t-p} dan m prediktor tambahan. Selanjutnya hitung residual \hat{v}_t dan jumlah kuadrat residual $SSR_1 = \sum \hat{v}_t^2$
3. Hitung $F = \frac{(SSR_0 - SSR_1) / m}{SSR_1 / (n - p - 1 - m)}$

dengan n adalah jumlah pengamatan

Dibawah hipotesis linearitas, F mendekati distribusi F dengan derajat bebas m dan $(n - p - 1 - m)$.

2.4 Neural Network

Neural Network (NN) adalah suatu metode komputasi yang meniru sistem jaringan saraf biologis. Metode ini menggunakan elemen perhitungan non-linier dasar yang disebut neuron yang diorganisasikan sebagai jaringan yang saling berhubungan, sehingga mirip dengan jaringan saraf manusia. NN ditentukan oleh tiga hal yaitu pola hubungan neuron (hubungan jaringan), metode untuk menentukan bobot penghubung (metode *training/learning*)

dan fungsi aktivasi (*output* suatu neuron). Setiap pola-pola informasi *input* dan *output* yang diberikan ke dalam NN diproses dalam neuron. NN telah banyak dikembangkan pada model peramalan data yang bersifat nonlinier. Kelebihan model ini adalah dapat mengaproksimasi suatu data yang berkelas besar dengan derajat akurasi yang besar dan tidak ada asumsi tertentu, tetapi melihat dari karakteristik data.

Multi Layer Perceptron (MLP) atau disebut juga *feedforward network* merupakan arsitektur NN yang tersusun dari beberapa *layer*. MLP memiliki tiga lapisan penyusun, yaitu

1. Lapisan *input*

Unit-unit di dalam lapisan *input* menerima pola inputan data dari luar yang menggambarkan suatu permasalahan.

2. Lapisan tersembunyi

Unit-unit di dalam lapisan tersembunyi, dimana outputnya tidak dapat diamati secara langsung.

3. Lapisan *output*

Unit-unit di dalam lapisan *output* yang merupakan solusi dari suatu permasalahan.

(Khashei & Bijari, 2011).

Backpropagation merupakan algoritma pembelajaran *neural network* dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron pada lapisan tersembunyi (Kusumadewi, 2004). Pembelajaran dari jaringan *backpropagation* terdiri dari tiga tahapan, yaitu menghitung arah maju dari pola *input* pembelajaran, menghitung *error backpropagation*, dan menentukan peubah bobot (Fausett, 1994).

Arsitektur dalam *backpropagation* disebut juga dengan *multilayer neural network*. Pada Gambar 2.1 akan ditunjukkan *multilayer neural network* dengan satu *layer* dari *hidden* unit (Z unit), unit *output* (Y unit) dan juga memiliki unit bias.

Gambar 2.1 menunjukkan arsitektur *backpropagation* dengan 1 *input*, ditambah sebuah bias, dan sebuah *layer* tersembunyi yang terdiri dari p unit, ditambah sebuah bias, serta 1 buah unit keluaran.

Dimana,


X_i : unit *input*

Y_k : unit *output*

Z_j : unit *hidden*

V_{ij} : bobot dari unit *input* menuju unit *hidden*

W_{jk} : bobot dari unit *hidden* menuju unit *output*



Gambar 2.1 Arsitektur *Backpropagation*

Fungsi aktivasi merupakan suatu fungsi yang digunakan untuk membandingkan antara hasil penjumlahan nilai-nilai semua bobot yang datang dengan suatu nilai ambang (*threshold*) tertentu pada tiap neuron (Kusumadewi, 2004). Dalam *backpropagation*, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat, yaitu:

1. Kontinu
2. Terdiferensial dengan mudah
3. Merupakan fungsi yang tidak turun

Salah satu fungsi yang memenuhi ketiga syarat tersebut adalah fungsi *sigmoid biner* yang memiliki *range* (0,1).

$$f_1(x) = \frac{1}{1 + e^{-x}} \quad (2.34)$$

Fungsi *sigmoid* memiliki nilai maksimum sebesar 1. Agar semua pola memiliki *range* yang sama seperti *sigmoid* yang dipakai, maka pola yang target nilainya lebih dari 1, pola masukan, dan keluaran harus ditransformasi lebih dulu.

Algoritma pembelajaran *backpropagation* dalam jaringan dengan satu *hidden layer* dan dengan fungsi aktivasi sigmoid biner adalah sebagai berikut.

Langkah 0 : inisialisasi bobot dengan bilangan acak kecil.

Langkah 1 : dilakukan langkah 2-9, jika kondisi penghentian belum terpenuhi.

Langkah 2 : setiap pasang data pelatihan, dilakukan langkah 3-8.

Fase I : propagansi maju (*feedforward*)

Langkah 3 : tiap unit *input* menerima sinyal dan meneruskannya ke unit tersembunyi di atasnya (unit *hidden*).

Langkah 4 : hitung semua sinyal *input* terboboti di unit *hidden* ($Z_j, j = 1, 2, \dots, p$)

$$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij}$$

Gunakan fungsi aktivasi untuk menghitung sinyal *hidden* yang selanjutnya akan diteruskan menuju *output* unit. Fungsi aktivasi yang digunakan pada *hidden layer* adalah fungsi sigmoid biner dengan rumus yang digunakan dapat dilihat pada Persamaan (2.34)

$$z_j = f(z_{in_j})$$

Langkah 5 : hitung semua sinyal *input* terboboti pada unit *output* y.

$$y_{in_k} = w_0 + \sum_{j=1}^p z_j w_{jk}$$

Gunakan fungsi aktivasi untuk menghitung sinyal *output*. Fungsi aktivasi *output* yang digunakan adalah fungsi linier, dapat dilihat pada Persamaan (2.35) berikut.

$$\begin{aligned} y_k &= f(y_{in_k}) \\ y_k &= \omega_{01} + \omega_{11}z_1 + \omega_{jk}z_j + \dots + \omega_{pm}z_p \end{aligned} \quad (2.35)$$

Fase II : propagansi mundur (*backpropagation*)

Langkah 6 : hitung faktor δ unit *output* berdasarkan kesalahan setiap unit keluaran y.

$$\delta_k = (t_k - y_k) f'(y_{in_k})$$

Hitung suku perubahan bobot w_{jk} dengan laju percepatan α

$$\Delta w_{jk} = \alpha \delta_k z_j$$

Langkah 7 : hitung faktor δ unit *hidden* berdasarkan kesalahan pada setiap unit z_j .

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk}$$

Kalikan dengan turunan dari fungsi aktivasi untuk menghitung errornya

$$\delta_j = \delta_{in_j} f'(z_{in_j})$$

Hitung suku perubahan bobot v_{ij}

$$\Delta v_{ij} = \alpha \delta_j x_i$$

- Fase III : perubahan bobot (*update*)
 Langkah 8 : hitung semua perubahan bobot. Perubahan bobot garis yang menuju ke unit *output*:

$$w_{jk} \text{ baru} = w_{jk} \text{ lama} + \Delta w_{jk}$$

Perubahan bobot yang menuju unit *hidden*

$$v_{ij} \text{ baru} = v_{ij} \text{ lama} + \Delta v_{ij}$$

- Langkah 9 : iterasi berhenti pada kondisi tertentu.

Bobot pada *neural network* merupakan penghubung antara satu *node* dengan *node* yang lain pada *layer* yang berbeda. Bobot merepresentasikan informasi yang digunakan pada jaringan untuk menyelesaikan suatu permasalahan (Fausett, 1994).

2.5 Hibrida ARIMA – NN

Hibrida adalah kombinasi dua atau lebih sistem dalam satu fungsi. Banyak peneliti menggunakan metode hibrida karena diharapkan dapat saling melengkapi karena dalam dunia nyata jarang ditemukan kejadian *time series* yang murni linier ataupun murni non-linier (Zheng & Zhong, 2011). Model ARIMA dapat menghasilkan peramalan yang baik pada kondisi yang non-linier untuk itu dilakukan kombinasi dengan NN yang menunjukkan performa yang baik jika data bersifat non-linier. Jadi model hibrida dapat membantu mengatasi struktur yang kompleks dari suatu data (Jan & Katarina, 2010).

Langkah pertama yang dilakukan dalam metode hibrida adalah menentukan model ARIMA yang berbasis hubungan linier dari parameter. selanjutnya model ARIMA digunakan sebagai *input* yaitu residual dari model ARIMA dimodelkan dengan NN. Kemudian yang terakhir adalah menggabungkan kedua model yaitu model ARIMA dan model NN (Faruk, 2010).

Secara umum kombinasi dari model *time series* yang memiliki struktur autokorelasi yang linier dan non-linier dapat dituliskan sebagai berikut.

$$y_t = L_t + N_t \quad (2.36)$$

Dimana L_t menunjukkan komponen linier dan N_t menunjukkan komponen non linier. Terdapat dua komponen yang harus di estimasi, yaitu model ARIMA digunakan untuk menyelesaikan kasus data linier dimana residual dari model linier masih mengandung informasi hubungan non linier. Secara matematis dapat dituliskan sebagai berikut.

$$e_t = y_t + \hat{L}_t \quad (2.37)$$

Dimana \hat{L}_t adalah nilai ramalan ARIMA pada waktu ke- t . nilai residual penting untuk mendiagnosa kecukupan model linier. Sebuah model linier dikatakan tidak cukup linier jika masih ada sisa hubungan korelasi linier dalam residual. Adanya pola non linier yang signifikan dalam residual akan menunjukkan keterbatasan dari model ARIMA. Dengan memodelkan residual menggunakan NN, maka hubungan non linier dapat teratasi (Zhang,2003). Persamaan dari residual untuk model NN dapat dituliskan sebagai berikut.

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-1}) + \varepsilon_t \quad (2.38)$$

Dimana f adalah fungsi non linier yang dijelaskan oleh *neural network*, sehingga fungsi kombinasi untuk memprediksi adalah $\hat{y}_t = \hat{L}_t + \hat{N}_t$.

2.6 Minyak dan Gas Bumi

Minyak dan gas bumi adalah campuran senyawa hidrokarbon, yang tersusun dari sebagian besar karbon dan hidrogen. Minyak dan gas bumi diduga secara tidak langsung berasal dari sisa-sisa organisme hidup. Sisa-sisa dari berbagai bentuk tumbuhan dan binatang laut yang hidup jutaan tahun lalu dan tertimbun dalam lumpur dan pasir di bawah laut tidak hanya membantu terbentuknya batuan sedimen, tetapi juga membantu terbentuknya endapan minyak dan gas alam (Utami, 2013). Minyak bumi terbentuk dari tiga faktor utama, yaitu:

1. Ada “bebatuan asal” yang secara geologis memungkinkan terjadinya pembentukan minyak bumi.
2. Adanya perpindahan hidrokarbon dari bebatuan asal menuju ke “bebatuan reservoir”.
3. Adanya jebakan geologis. Struktur geologis kulit bumi yang tidak teratur bentuknya, akibatnya pergerakan dari bumi sendiri dan erosi oleh air dan angin secara terus-menerus dapat menciptakan suatu “ruangan” bawah tanah yang menjadi jebakan hidrokarbon. Jika jebakan ini dilingkupi oleh lapisan yang *impermeable*, maka hidrokarbon tadi akan diam di tempat dan tidak bisa bergerak kemana-mana lagi.

Jenis-jenis minyak bumi digolongkan menjadi 4 macam menurut umur dan letak kedalamannya, yaitu *young-shallow*, *old-shallow*, *young-deep*, dan *old-deep*. Para geologis umumnya sependapat bahwa minyak bumi terbentuk selama jutaan tahun dari organisme, tumbuhan, dan hewan, berukuran sangat kecil yang hidup di lautan purba. Begitu organisme laut ini mati, badannya terkubur di dasar lautan lalu tertimbun pasir dan lumpur, membentuk lapisan yang kaya zat organik dan akhirnya menjadi batuan endapan. Proses ini berulang terus, satu lapisan menutup lapisan sebelumnya.

Terdapat beberapa cara untuk menemukan minyak dan gas bumi. Setelah yakin menemukan minyak selanjutnya adalah membangun sumur yang meliputi pemboran (*drilling*), memasang tubular sumur (*casing*), dan penyemenan (*cementing*). Lalu proses *completion* untuk membuat sumur siap digunakan. Ketika sumur sudah dapat digunakan, selanjutnya secara berkala dilakukan pengujian kandungan minyak bumi dari sumur tersebut atau biasa disebut *well testing*. Tujuan dari *well testing* adalah untuk memastikan apakah sumur akan mengalir dan berproduksi, untuk mengetahui kualitas minyak dan gas bumi, untuk memperkirakan berapa lama reservoirnya akan berproduksi, dan untuk

memperkirakan berapa lama akan menghasilkan keuntungan secara ekonomi.

Ketika sumur tidak lagi beroperasi dengan baik dengan kata lain kandungan minyak yang dikeluarkan kualitasnya tidak baik dan sedikit, maka sumur tersebut perlu untuk diberi stimulus. Stimulus adalah proses mekanikal dan/atau *chemical* yang ditujukan untuk menaikkan laju produksi dari sumur. Terdapat 3 metode stimulasi yang semuanya memakai fluida khusus yang dipompakan ke dalam sumur.

1. *Wellbore cleanup* : fluida dipompakan ke dalam sumur, tidak sampai ke formasi. Tujuan utamanya untuk membersihkan lubang sumur dari berbagai macam kotoran.
2. Stimulasi matriks : fluida diinjeksikan ke dalam formasi hidrokarbon tanpa memecahkannya. Fluida ini akan “memakan” kotoran di sekitar lubang sumur dan membersihkannya, sehingga fluida hidrokarbon akan mudah mengalir masuk ke dalam lubang sumur.
3. *Fracturing* : fluida diinjeksikan ke dalam formasi dengan laju dan tekanan tertentu, sehingga formasi akan pecah atau merekah. Rekahan ini akan menjadi jalan tol berkonduktivitas tinggi dimana fluida hidrokarbon dapat mengalir dengan lebih optimum masuk ke dalam sumur.

(Samperuru, 2007).

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan pada penelitian ini merupakan data sekunder, yaitu data jumlah produksi minyak dan gas bumi selama tahun 2015 dari bulan Januari hingga Desember yang berasal pada *platform* “MK” di PT “X”. Pengukuran data dilakukan setiap 2 jam dalam sehari yang kemudian dihitung kumulatif setiap hari, sehingga data yang digunakan merupakan data harian sebanyak 365 data.

Variabel yang akan digunakan pada penelitian ini adalah jumlah produksi minyak dan gas bumi di *platform* “MK” setiap hari dalam satuan barel untuk minyak dan satuan mScf untuk gas. Struktur data yang digunakan dalam penelitian ini dapat dilihat pada Tabel 3.1.

Tabel 3.1 Struktur Data Penelitian

Tanggal	Hari	Jumlah Minyak	Jumlah Gas
01/01/2015	Kamis	$Z_{1,1}$	$Z_{1,2}$
02/01/2015	Jumat	$Z_{2,1}$	$Z_{2,2}$
03/01/2015	Sabtu	$Z_{3,1}$	$Z_{3,2}$
⋮	⋮	⋮	⋮
31/12/2015	Kamis	$Z_{365,1}$	$Z_{365,2}$

3.2 Langkah Analisis

Langkah-langkah analisis yang digunakan dalam penelitian ini dapat dijabarkan sebagai berikut.

1. Mendeskripsikan data jumlah produksi minyak bumi di *platform* “MK”.
2. Membagi data *time series* menjadi data *in sample* dan *out sampel* dan memodelkan data menggunakan

metode ARIMA, *neural network*, dan hibrida ARIMA-NN

Metode ARIMA

- a. Membuat *time series* plot.
- b. Melakukan pengecekan stasioneritas terhadap *varians* dan *mean*. Jika data tidak stasioner dalam *varians*, maka dilakukan transformasi. Sedangkan jika data tidak stasioner dalam *mean*, maka dilakukan *differencing*.
- c. Melakukan identifikasi model data jumlah produksi minyak bumi di *platform* “MK” berdasarkan plot ACF dan PACF.
- d. Melakukan estimasi dan pengujian parameter berdasarkan model yang telah diduga.
- e. Melakukan pengujian asumsi yaitu, *white noise* dan distribusi normal. Jika data tidak berdistribusi normal, maka dapat dideteksi dengan *outlier*.
- f. Pemilihan model terbaik dengan melihat nilai RMSE paling rendah.

Metode Neural Network

- a. Menentukan arsitektur *neural network* yaitu menentukan banyak *input*, jumlah neuron dalam *hidden layer*, dan fungsi aktivasi.

Dalam menentukan input pada *neural network* didasarkan pada model terbaik ARIMA, jika model terbaik adalah AR atau ARMA maka input yang digunakan sebanyak orde AR. Sedangkan jika model terbaik MA, maka input *neural network* berdasarkan jumlah lag yang keluar pada plot PACF yang terbentuk (Crone dan Kourentzes, 2009).


Jumlah neuron yang digunakan dalam penelitian ini berbeda-beda, mulai dari 1 neuron sampai 10 neuron. Masing-masing neuron diulang sebanyak 5 kali. Sedangkan fungsi aktivasi yang digunakan

adalah fungsi sigmoid biner pada *hidden layer* dan fungsi linier pada *output*.


- b. Melakukan pelatihan (*in-sampling training*) pada data pelatihan dengan memasukkan bobot dan arsitektur *neural network* yang telah didapatkan untuk mendapatkan model terbaik.
- c. Menghitung nilai RMSE dan memilih model terbaik berdasarkan nilai RMSE terkecil.

Metode Hibrida ARIMA-Neural Network

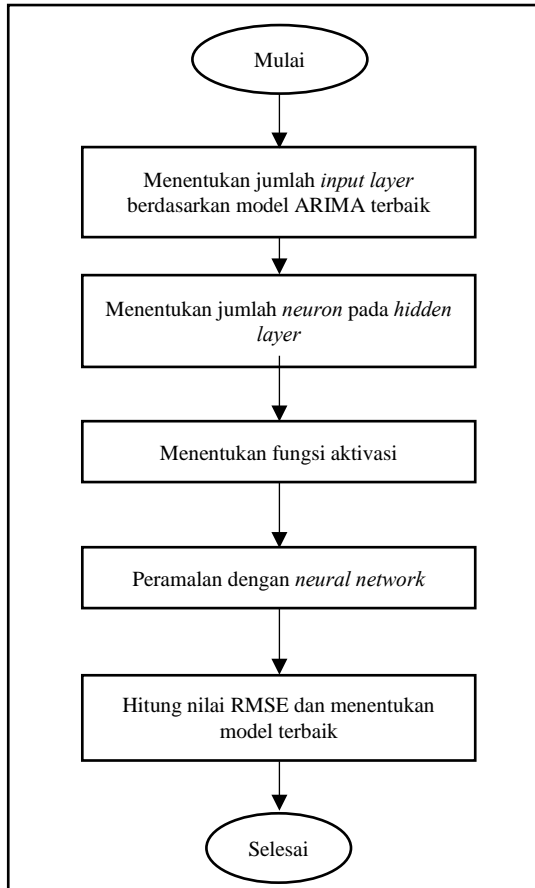
- a. Menentukan model ARIMA terbaik
 - b. Melakukan pemodelan dengan metode ARIMA
 - c. Menentukan *input*, jumlah neuron, dan fungsi aktivasi yang digunakan. *Input* yang digunakan sama dengan model *neural network*, namun yang digunakan adalah nilai residual dari model ARIMA terbaik. Sedangkan jumlah neuron dan fungsi aktivasi yang digunakan sama seperti *neural network*.
 - d. Menentukan model terbaik dari metode hibrida ARIMA – *neural network* dengan melihat nilai RMSE terendah.
 - g. Menggabungkan model a dan c sehingga didapatkan model hibrida ARIMA – *neural network*.
3. Membandingkan model ARIMA, *neural network*, dan hibrida ARIMA-NN berdasarkan nilai RMSE.
 4. Meramalkan jumlah produksi minyak dan gas bumi di *platform* “MK” menggunakan model terbaik.




Gambar 3.1 Diagram Alir Langkah Analisis



Gambar 3.2 Diagram Alir Metode ARIMA



Gambar 3.3 Diagram Alir Metode *Neural Network*



Gambar 3.4 Diagram Alir Hibrida ARIMA-NN

“Halaman ini sengaja dikosongkan”

BAB IV ANALISIS DAN PEMBAHASAN

Minyak dan gas bumi merupakan salah satu sumber daya alam yang tidak dapat diperbarui. Salah satu cara terpenting dalam pengambilan minyak dan gas bumi adalah dengan membangun sumur-sumur. Ada saatnya sumur-sumur tersebut mulai melemah dalam menyedot minyak dan gas bumi. Ketika sumur tersebut mulai melemah, hal yang perlu dilakukan adalah dengan memberikan *treatment* terhadap sumur tersebut. Dalam penelitian ini akan meramalkan jumlah produksi minyak dan gas bumi selama 14 hari ke depan, sehingga dapat diketahui apakah selama 14 hari ke depan tersebut perlu dilakukan *treatment* terhadap sumur. Data yang digunakan adalah data jumlah produksi minyak dan gas bumi pada *platform* “MK” di PT X. Dalam analisisnya menggunakan 3 metode sebagai perbandingan, yaitu ARIMA, *neural network*, dan hibrida ARIMA-*neural network*.

4.1 Deskriptif Produksi Minyak dan Gas Bumi

Langkah pertama yang perlu dilakukan dalam analisis ini adalah melihat karakteristik data dari hasil produksi minyak dan gas bumi di *platform* “MK” selama tahun 2015. Metode yang tepat digunakan dalam melihat karakteristik data adalah statistika deskriptif. Data yang digunakan terdapat pada Lampiran 1 dan Lampiran 2. Hasil karakteristik jumlah produksi minyak dan gas bumi yang diperoleh dapat dilihat pada Tabel 4.1.


Tabel 4.1 Deskriptif Jumlah Produksi Minyak dan Gas Bumi

Variabel	Minyak Bumi	Gas Bumi
Rata-rata	2555,6	5704,1
Maximum	4107,0	8718,0
Minimum	649,5	1577,0
Varians	421576,8	2197042,9
Median	2587,6	5790,0

Berdasarkan hasil statistika deskriptif pada Tabel 4.1 diketahui bahwa rata-rata jumlah produksi minyak bumi setiap harinya sebanyak 2555,6 barel dengan median sebesar 2587,6. Artinya adalah hasil produksi minyak bumi setiap hari hampir sama jumlahnya dengan variansi sebesar 421576,8, jumlah produksi terendah sebesar 649,5 barel, dan jumlah produksi tertinggi sebesar 4107 barel.

Tidak berbeda jauh dengan karakteristik pada minyak bumi, diketahui bahwa rata-rata produksi gas bumi setiap hari selama tahun 2015 sebesar 5704,123 barel dengan median sebesar 5790. Rata-rata jumlah produksi gas bumi setiap hari cenderung konstan karena nilai rata-rata dengan nilai median tidak berbeda signifikan. Variansi dari jumlah produksi gas bumi sebesar 2197042,9 dengan jumlah produksi terendah sebesar 1577 mScf dan jumlah produksi tertinggi sebesar 8718 mScf.

Karakteristik jumlah produksi minyak bumi setiap hari juga dapat dilihat menggunakan box-plot. Data yang digunakan terdapat pada Lampiran 1, dan hasil yang diperoleh dapat dilihat pada Gambar 1 berikut. Nilai pada box plot data jumlah produksi minyak bumi terdapat pada Lampiran 3.




Gambar 4.1 Boxplot Produksi Minyak Bumi

Berdasarkan Gambar 4.1 di atas terlihat bahwa garis median atau garis tengah dari masing-masing plot hampir sama. Dimana hari 1-7 menjelaskan hari Senin-Minggu. Hal tersebut menjelaskan

bahwa rata-rata jumlah produksi minyak bumi setiap hari cenderung konstan selama tahun 2015, yaitu sekitar 2500 barel setiap hari. Jumlah produksi terendah sebesar 649,5 barel terjadi pada hari Sabtu, dengan median sebesar 2593,5 barel, kuartil atas sebesar 3041,3 dan kuartil bawah sebesar 2018,13 barel.

Selanjutnya melihat karakteristik gas bumi melalui box-plot. Hasil yang diperoleh terdapat pada Gambar 4.2 berikut. Hasil nilai dari box plot data jumlah produksi gas bumi selengkapnya terdapat pada Lampiran 4.



Gambar 4.2 Boxplot Produksi Gas Bumi

Berdasarkan hasil dari box-plot di atas dapat dilihat bahwa garis tengah dari box-plot setiap hari selama tahun 2015 cenderung konstan. Artinya adalah rata-rata hasil produksi gas bumi setiap hari tidak berbeda jauh yaitu sebesar 5500 mScf. Berdasarkan gambar tersebut terlihat bahwa pada hari Sabtu selama tahun 2015 terdapat jumlah produksi yang sangat tinggi dan sangat rendah. Jumlah produksi paling rendah sebesar 1577 mScf dengan median sebesar 6008,5, kuartil atas sebesar 6858,5 mScf, dan kuartil bawah sebesar 4398,5 mScf.

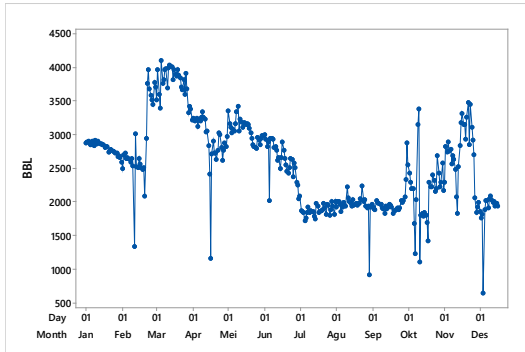
4.2 Pemodelan Produksi Minyak Bumi

Analisis selanjutnya setelah mengetahui karakteristik data adalah memodelkan jumlah produksi minyak bumi selama tahun 2015. Dalam memodelkan jumlah produksi minyak dan gas bumi

digunakan tiga metode sebagai perbandingan, yaitu metode ARIMA, *neural network*, dan hibrida ARIMA-*neural network*. Pemodelan pertama menggunakan metode ARIMA pada data jumlah produksi minyak bumi tahun 2015.

4.2.1 Pemodelan Produksi Minyak Bumi Dengan ARIMA

Langkah pertama yang harus dilakukan dalam memodelkan data dengan ARIMA adalah membuat plot data. Data yang digunakan merupakan data jumlah produksi minyak bumi yang terdapat pada Lampiran 1. Plot data *time series* dapat dilihat pada Gambar 4.3.



Gambar 4.3 Time Series Plot Produksi Minyak Bumi


Berdasarkan time series plot di atas diketahui bahwa data jumlah produksi minyak bumi tahun 2015 memiliki pola yang fluktuatif. Selain itu dari gambar di atas dapat dilihat bahwa rata-rata produksi minyak bumi selama tahun 2015 tidak jauh berbeda, hanya saja ada produksi minyak bumi yang sangat rendah. Hal tersebut diduga bahwa sumur pada *platform* “MK” sedang ada perbaikan.

Gambar *time series* plot di atas dan gambar box-plot pada jumlah produksi minyak bumi sebelumnya dapat terlihat bahwa, data produksi minyak bumi tahun 2015 di *platform* “MK” diduga belum stasioner. Untuk memastikannya dilakukan pengecekan stasioneritas dalam varians dan dalam mean. Sebelum melakukan

pengecekan stasioneritas data, data produksi minyak bumi dibagi menjadi data *in sample* dan *out sample*. Dimana data *out sample* yang digunakan sebanyak 14 data terakhir.

a. Stasioneritas Data Produksi Minyak Bumi

Pengecekan stasioneritas yang dilakukan pertama adalah pengecekan stasioneritas data dalam varians menggunakan transformasi Box-Cox. Data yang digunakan terdapat pada Lampiran 1 sebanyak 351 data. Hasil transformasi yang diperoleh dapat dilihat pada Gambar 4.4 berikut.




Gambar 4.4 Transformasi Box-cox Produksi Minyak Bumi

Gambar 4.4 di atas menjelaskan bahwa data produksi minyak bumi pada tahun 2015 di *platform* “MK” sudah stasioner dalam varians. Karena nilai lambda atau *rounded value* sudah berada di antara nilai *lower* dan *upper*, sehingga data dikatakan sudah stasioner dalam varians.

Pengecekan stasioneritas selanjutnya adalah stasioneritas dalam mean. Terdapat beberapa cara yang dapat digunakan dalam melakukan pengecekan stasioneritas dalam mean, salah satunya adalah menggunakan box-plot. Gambar box-plot data produksi minyak bumi, yaitu Gambar 4.1 menunjukkan bahwa rata-rata produksi minyak bumi tidak berada di sekitar angka 0, sehingga data dikatakan belum stasioner dalam mean. Cara lain yang dapat

digunakan adalah dengan melihat plot ACF. Hasil dari plot ACF dapat dilihat pada Gambar 4.5.

Berdasarkan plot ACF pada Gambar 4.5, dapat dilihat bahwa plot tersebut turun lambat. Artinya adalah data produksi minyak bumi tahun 2015 di *platform* “MK” terbukti belum stasioner dalam mean. Untuk membuat data menjadi stasioner dalam mean, perlu dilakukan *differencing* sebanyak 1 kali.




Gambar 4.5 Plot ACF Produksi Minyak Bumi

b. Pendugaan Model ARIMA Data Produksi Minyak Bumi


Setelah dilakukan *differencing*, selanjutnya melihat plot ACF dan PACF untuk menduga model yang terbentuk. Data yang digunakan masih sama dengan sebelumnya, yaitu data *in sample* dari produksi minyak bumi yang terdapat pada Lampiran 1 sebanyak 151 data. Plot ACF dan PACF yang diperoleh dapat dilihat pada Gambar 4.6 dan Gambar 4.7.

Plot ACF pada Gambar 4.6 menunjukkan pola *cuts off* setelah lag 2, terlihat dari 2 lag pertama keluar dari batas sedangkan selanjutnya sudah mendekati angka 0 atau sudah berada di dalam batas. Nilai dari ACF pada setiap lag dapat dilihat pada Lampiran 5.



Gambar 4.6 Plot ACF Produksi Minyak Bumi Setelah *Differencing*

Selanjutnya melihat plot PACF agar dapat menduga model ARIMA yang terbentuk. Berikut plot PACF yang diperoleh.



Gambar 4.7 Plot PACF Produksi Minyak Bumi Setelah *Differencing*

Plot PACF yang terbentuk seperti gambar di atas menunjukkan pola *dies down*. Terdapat 3 lag di awal yang keluar dari batas, sedangkan lag selanjutnya sudah ada dalam batas. Nilai PACF pada setiap lag dapat dilihat pada Lampiran 6.

Berdasarkan gambar dari plot ACF dan PACF terdapat dua model yang diduga, yaitu ARIMA (0,1,2) dan ARIMA (0,1,1). Untuk memastikan model mana yang terpilih, selanjutnya dilakukan uji signifikansi model.

c. Uji Signifikansi Parameter Data Produksi Minyak Bumi

Uji signifikansi diperlukan untuk menguji model-model dugaan apakah parameter yang diduga tersebut benar-benar berpengaruh signifikan terhadap model. Data yang digunakan merupakan data *in sample* dari jumlah produksi minyak bumi sebanyak 151 data, terdapat pada Lampiran 1. Hasil dari uji signifikansi model ditampilkan dalam Tabel 4.2 berikut.

Tabel 4.2 Uji Signifikansi Parameter Data Produksi Minyak Bumi

Model	Parameter	Koefisien	P-Value	Keterangan
ARIMA (0,1,1)	θ_1	0,0468	0,000	Signifikan
ARIMA (0,1,2)	θ_1	0,3929	0,000	Signifikan
	θ_2	0,1853	0,000	Signifikan

Berdasarkan hasil dari uji signifikansi parameter di atas, diketahui bahwa 2 model dugaan tersebut memiliki parameter-parameter yang signifikan berpengaruh terhadap model. Selanjutnya menguji kesesuaian model untuk mengetahui model dugaan tersebut memenuhi asumsi yang diperlukan atau tidak.

d. Uji Kesesuaian Model Data Produksi Minyak Bumi

Uji kesesuaian model diperlukan untuk menguji model-model yang diduga sebelumnya sudah memenuhi asumsi atau belum. Asumsi yang dibutuhkan untuk mendapatkan nilai ramalan yang akurat adalah white noise dan berdistribusi normal. Data yang digunakan sama dengan sebelumnya yaitu data *insample* dari jumlah produksi minyak bumi tahun 2015 di *platform* “MK” yang terdapat pada Lampiran 1. Hasil uji kesesuaian model dapat dilihat pada Tabel 4.3.

Tabel 4.3 Uji Kesesuaian Model Data Produksi Minyak Bumi

Lag <i>White Noise</i>	ARIMA (0,1,1)		ARIMA (0,1,2)	
	χ^2	P-Value	χ^2	P-Value
12	22,5	0,021	10,5	0,402
24	25,7	0,315	14,6	0,879
36	32,9	0,567	21,8	0,948
48	44,9	0,559	32,3	0,937

Berdasarkan hasil dari uji kesesuaian model di atas diketahui bahwa model ARIMA (0,1,1) dan ARIMA (0,1,2) tidak memenuhi asumsi white noise. Begitu juga dengan nilai *P-Value* pada uji distribusi normal yaitu kurang dari 0,010 pada kedua model. Artinya residual belum berdistribusi normal, sehingga diperlukan deteksi *outlier* agar residual model ARIMA tersebut dapat memenuhi asumsi. Langkah-langkah dalam deteksi *outlier* hampir sama dengan pemodelan ARIMA, namun terdapat *outlier* yang dimasukkan ke dalam model.

Langkah pertama dalam deteksi *outlier* adalah uji signifikansi parameter. Data yang digunakan adalah data *in sample* jumlah produksi minyak bumi, sebanyak 151 data dapat dilihat pada Lampiran 1. Hasil dari uji signifikansi parameter pada model ARIMA (0,1,1) dapat dilihat pada Tabel 4.4 berikut.

Tabel 4.4 Uji Signifikansi Parameter ARIMA (0,1,1) Deteksi *Outlier*
Data Jumlah Produksi Minyak Bumi

Parameter	Estimasi	<i>P-Value</i>	Parameter	Estimasi	<i>P-Value</i>
θ_1	0,76366	<0,0001	ω_{341}	172,07119	0,0002
ω_{107}	-1607,4	<0,0001	ω_{42}	-1247,6	<0,0001
ω_{242}	-1028,8	<0,0001	ω_{130}	297,01932	<0,0001
ω_{157}	-896,15311	<0,0001	ω_{327}	-318,09263	<0,0001
ω_{281}	-1004,6	<0,0001	ω_{236}	255,04125	<0,0001
ω_{285}	-1472,9	<0,0001	ω_{223}	253,10128	<0,0001
ω_{283}	1023,4	<0,0001	ω_{70}	-274,03716	<0,0001
ω_{53}	1131,4	<0,0001	ω_{324}	-236,6144	0,0002
ω_{332}	-1164,4	<0,0001	ω_{114}	248,28236	<0,0001
ω_{319}	606,22598	<0,0001	ω_{122}	238,23349	0,0003
ω_{293}	461,86504	<0,0001	ω_{129}	215,77302	0,0005
ω_{274}	607,32602	<0,0001	ω_{184}	-232,8966	<0,0001
ω_{317}	-739,95849	<0,0001	ω_{86}	229,74941	0,0004
ω_{285}	-685,76844	<0,0001	ω_{282}	-213,6114	0,0025
ω_{307}	558,49962	<0,0001	ω_{64}	-231,83995	0,0005
ω_{51}	-441,67511	<0,0001	ω_{178}	272,28555	<0,0001
ω_{106}	-360,11899	<0,0001	ω_{91}	-153,45892	0,0011

Tabel 4.4 (Lanjutan)

Parameter	Estimasi	P-Value	Parameter	Estimasi	P-Value
ω_{88}	-314,35046	<0,0001	ω_{117}	-173,21011	0,0057
ω_{316}	-495,55646	<0,0001	ω_{103}	-192,22907	0,0002
ω_{182}	-234,66937	<0,0001	ω_{339}	-1185	<0,0001
ω_{280}	-559,71131	<0,0001	ω_{115}	212,73687	0,0007
ω_{65}	325,13584	<0,0001	ω_{336}	-161,18199	0,0012
ω_{122}	307,56076	<0,0001	ω_{75}	-102,45686	0,0178
ω_{43}	436,38844	<0,0001	ω_{269}	127,30958	0,0044
ω_{328}	289,56633	<0,0001	ω_{330}	-244,90216	0,0004
ω_{326}	303,0484	<0,0001	ω_{169}	171,57799	0,0059
ω_{300}	446,86055	<0,0001	ω_{58}	-191,37112	0,0022
ω_{62}	337,25977	<0,0001	ω_{301}	191,31928	0,0021
ω_{273}	237,50845	<0,0001	ω_{179}	209,26951	0,0018
ω_{105}	-275,38492	<0,0001	ω_{32}	-169,23192	0,0057
ω_{52}	408,2248	<0,0001	ω_{296}	166,63002	0,0072
ω_{304}	344,65749	<0,0001	ω_{112}	-133,05534	0,0327
ω_{304}	344,65749	<0,0001	ω_{112}	-133,05534	0,0327
ω_{292}	-358,41817	<0,0001	ω_{276}	171,9738	0,0084
ω_{54}	308,55519	<0,0001	ω_{173}	-167,37509	0,0076
ω_{142}	-229,64054	<0,0001	ω_{121}	166,2942	0,0114
ω_{164}	-190,65906	<0,0001	ω_{109}	146,68845	0,0195
ω_{331}	-465,90219	<0,0001	ω_{208}	-127,08358	0,0366
ω_{168}	286,82338	<0,0001	ω_{161}	-127,41319	0,0071
ω_{82}	-194,41864	<0,0001	ω_{197}	99,79886	0,0178
ω_{319}	-333,90867	<0,0001	ω_{172}	-135,58269	0,0297
ω_{312}	-207,75899	<0,0001	ω_{333}	-156,11614	0,0191
ω_{275}	293,89992	<0,0001	ω_{321}	140,29661	0,0292
ω_{177}	-287,95324	<0,0001			

Berdasarkan hasil dari uji signifikansi parameter pada deteksi outlier, diketahui bahwa menggunakan taraf signifikan 5% parameter θ_1 dan 84 outlier yang terdeteksi sudah signifikan berpengaruh terhadap model. Langkah selanjutnya adalah melakukan uji kesesuaian model dengan outlier yang telah

terdeteksi. Tabel 4.5 berikut menunjukkan hasil dari uji kesesuaian model ARIMA (0,1,1).

Tabel 4.5 Uji Kesesuaian Model ARIMA (0,1,1) Deteksi *Outlier*
Data Jumlah Produksi Minyak Bumi

White Noise	P-Value	Keterangan
Lag 6	0,1068	White Noise
Lag 12	0,5276	White Noise
Lag 18	0,1745	White Noise
Lag 24	0,1835	White Noise
Lag 30	0,2409	White Noise
Lag 36	0,2155	White Noise
Lag 42	0,3781	White Noise
Lag 48	0,5853	White Noise

Dilihat pada Tabel 4.5 di atas diketahui bahwa model ARIMA (0,1,1) sudah memenuhi asumsi white noise menggunakan taraf signifikan 5%, yang artinya residual sudah identik dan independen. Namun pada pengujian berdistribusi normal, diperoleh nilai P-Value sebesar 0,0221 yang artinya residual belum memenuhi asumsi distribusi normal.

Selanjutnya melakukan deteksi *outlier* pada model ARIMA (0,1,2). Langkah-langkah dalam deteksi outlier sama seperti sebelumnya, yaitu uji signifikansi parameter dan uji kesesuaian model. Tabel 4.6 berikut merupakan hasil dari uji signifikansi parameter.

Tabel 4.6 Uji Signifikansi Parameter ARIMA (0,1,2) Deteksi *Outlier*
Data Jumlah Produksi Minyak Bumi

Parameter	Estimasi	P-Value	Parameter	Estimasi	P-Value
θ_1	0,19187	0,0003	ω_{70}	-268,21318	<0,0001
θ_2	0,59695	<0,0001	ω_{131}	-248,56176	<0,0001
ω_{107}	-1436,6	<0,0001	ω_{292}	-327,01794	<0,0001
ω_{42}	-1188,3	<0,0001	ω_{236}	261,41705	<0,0001
ω_{339}	-1223,5	<0,0001	ω_{223}	208,06741	0,0002
ω_{242}	-991,30519	<0,0001	ω_{318}	-671,05442	<0,0001

Tabel 4.6 (Lanjutan)

Parameter	Estimasi	P-Value	Parameter	Estimasi	P-Value
ω_{157}	-923,19529	<0,0001	ω_{317}	-284,548	0,0005
ω_{52}	793,88657	<0,0001	ω_{331}	-344,72081	<0,0001
ω_{332}	-731,00219	<0,0001	ω_{177}	-252,98991	<0,0001
ω_{284}	1563,1	<0,0001	ω_{109}	222,18256	0,0004
ω_{283}	1240,8	<0,0001	ω_{58}	-179,15227	0,0017
ω_{293}	804,07453	<0,0001	ω_{103}	-260,27362	<0,0001
ω_{281}	-617,30874	<0,0001	ω_{312}	-294,636	<0,0001
ω_{327}	-559,34657	<0,0001	ω_{180}	-373,02311	<0,0001
ω_{318}	1370,1	<0,0001	ω_{326}	208,84239	0,0031
ω_{280}	-516,52443	<0,0001	ω_{114}	180,76661	0,0031
ω_{307}	568,77268	<0,0001	ω_{164}	-188,61107	0,0024
ω_{62}	425,97861	<0,0001	ω_{85}	-242,25789	0,0003
ω_{300}	297,95531	<0,0001	ω_{75}	-153,67601	0,0054
ω_{329}	-377,74979	<0,0001	ω_{274}	458,18508	<0,0001
ω_{316}	-433,57419	<0,0001	ω_{51}	-466,98178	<0,0001
ω_{106}	-340,62876	<0,0001	ω_{273}	368,55431	<0,0001
ω_{53}	764,69798	<0,0001	ω_{184}	-320,69649	<0,0001
ω_{285}	-675,79607	<0,0001	ω_{54}	247,80846	<0,0001
ω_{43}	409,36267	<0,0001	ω_{141}	-199,02592	0,0005
ω_{304}	301,4483	<0,0001	ω_{319}	-294,55253	0,0003
ω_{88}	-363,73408	<0,0001	ω_{64}	-694,8939	<0,0001
ω_{122}	346,56078	<0,0001	ω_{64}	327,25633	<0,0001
ω_{324}	-295,10473	<0,0001	ω_{161}	-131,28582	0,0332
ω_{86}	283,58633	<0,0001			

Berdasarkan hasil uji signifikansi parameter model ARIMA (0,1,2) pada Tabel 4.6, diketahui bahwa parameter θ_1 dan θ_2 serta 57 outlier yang terdeteksi sudah signifikan berpengaruh terhadap model yang terbentuk. Selanjutnya melakukan uji kesesuaian model, untuk melihat apakah residual dari model ARIMA (0,1,2) sudah memenuhi asumsi setelah dilakukan deteksi *outlier*. Hasil dari uji kesesuaian model ARIMA (0,1,2) dapat dilihat pada Tabel 4.7.

Tabel 4.7 Uji Kesesuaian Model ARIMA (0,1,2) Deteksi *Outlier*
Data Jumlah Produksi Minyak Bumi

White Noise	P-Value	Keterangan
Lag 6	0,6432	White Noise
Lag 12	0,8255	White Noise
Lag 18	0,9104	White Noise
Lag 24	0,9012	White Noise
Lag 30	0,9332	White Noise
Lag 36	0,9025	White Noise
Lag 42	0,8328	White Noise
Lag 48	0,924	White Noise

Hasil dari uji kesesuaian model ARIMA (0,1,2) pada Tabel 4.7, dapat dilihat bahwa nilai P-Value di semua lag sudah lebih dari taraf signifikan yang digunakan yaitu sebesar 0,05 sehingga dapat dikatakan residual sudah memenuhi asumsi *white noise*. Dalam uji residual berdistribusi normal diperoleh nilai P-Value sebesar 0,1023 sudah lebih besar dari 0,05, sehingga dapat disimpulkan bahwa pada model ARIMA (0,1,2) residual sudah memenuhi asumsi *white noise* dan berdistribusi normal. Selanjutnya memilih model terbaik pada jumlah produksi minyak bumi.

e. Pemilihan Model Terbaik Data Produksi Minyak Bumi

Pemilihan model terbaik digunakan untuk menentukan model yang paling baik di antara model dugaan yang ada. Penentuan model terbaik berdasarkan data in sample dan out sample. Kriteria yang digunakan untuk menentukan model terbaik adalah nilai RMSE yang paling kecil.

Data yang digunakan untuk menentukan model terbaik adalah dzata produksi minyak bumi yang terdapat pada Lampiran 1. Hasil dari pemilihan model terbaik dapat dilihat pada Tabel 4.8 berikut.

Tabel 4.8 Pemilihan Model Terbaik Data Jumlah Produksi Minyak Bumi

Model	RMSE	
	In sample	Out Sample
ARIMA (0,1,1)	65,5	61,48
ARIMA (0,1,2)	71,47	48,92

Berdasarkan dari nilai RMSE *out sample* yang terkecil terdapat pada model ARIMA (0,1,2), sehingga yang terpilih sebagai model terbaik adalah model ARIMA (0,1,2) dengan semua asumsi yang sudah terpenuhi. Hasil analisis menggunakan ARIMA selengkapnya dapat dilihat pada Lampiran 11. Persamaan matematik dari model ARIMA (0,1,2) dapat dituliskan sebagai berikut.

$$\begin{aligned}
 Z_t = & Z_{t-1} - 0,19187a_{t-1} - 0,59695a_{t-2} + a_t - 1,436,6I_t^{107} - 1188,3I_t^{42} \\
 & - 1223,5I_t^{339} - 991,3I_t^{242} - 923,2I_t^{157} + \frac{793,9}{(1-B)}I_t^{52} - \frac{731,0}{(1-B)}I_t^{332} \\
 & + 1563,1I_t^{284} + 1240,8I_t^{283} + \frac{804,1}{(1-B)}I_t^{293} - 617,3I_t^{281} - 559,3I_t^{327} \\
 & + \frac{1370,1}{(1-B)}I_t^{318} - \frac{516,5}{(1-B)}I_t^{280} + \frac{568,8}{(1-B)}I_t^{307} + 426,0I_t^{62} + 298,0I_t^{300} \\
 & - \frac{377,7}{(1-B)}I_t^{329} - \frac{433,6}{(1-B)}I_t^{316} - \frac{340,6}{(1-B)}I_t^{106} + \frac{764,7}{(1-B)}I_t^{53} - 675,8I_t^{285} \\
 & + 409,4I_t^{43} + 301,4I_t^{304} - \frac{363,7}{(1-B)}I_t^{88} + \frac{346,6}{(1-B)}I_t^{122} - 295,1I_t^{324} \\
 & + 283,6I_t^{86} - 268,2I_t^{70} - 248,5I_t^{131} - \frac{327,0}{(1-B)}I_t^{292} + 261,4I_t^{236} \\
 & + 208,1I_t^{223} - 671,1I_t^{318} - \frac{284,5}{(1-B)}I_t^{317} - \frac{344,7}{(1-B)}I_t^{331} - 253,0I_t^{177} \\
 & + 222,2I_t^{109} - 179,2I_t^{58} - \frac{260,3}{(1-B)}I_t^{103} - \frac{294,6}{(1-B)}I_t^{312} - \frac{373,0}{(1-B)}I_t^{180}
 \end{aligned}$$

$$\begin{aligned}
& + \frac{208,8}{(1-B)} I_t^{326} + \frac{180,8}{(1-B)} I_t^{114} - \frac{188,6}{(1-B)} I_t^{164} - \frac{242,3}{(1-B)} I_t^{85} - 153,7 I_t^{75} \\
& + 458,2 I_t^{274} - \frac{467,0}{(1-B)} I_t^{51} + \frac{368,6}{(1-B)} I_t^{273} - \frac{320,7}{(1-B)} I_t^{184} + 247,8 I_t^{54} \\
& - \frac{199,0}{(1-B)} I_t^{141} - 294,6 I_t^{319} - 694,9 I_t^{64} + \frac{327,3}{(1-B)} I_t^{64} - \frac{131,3}{(1-B)} I_t^{161}
\end{aligned}$$

Model tersebut memiliki arti bahwa jumlah produksi minyak bumi pada hari ini berhubungan dengan jumlah produksi minyak bumi pada 1 hari sebelumnya.

4.2.2 Pemodelan Produksi Minyak Bumi Dengan *Neural Network*

Analisis selanjutnya adalah memodelkan jumlah produksi minyak bumi menggunakan metode *neural network*. Sebelum melakukan pemodelan menggunakan *neural network*, sebaiknya melakukan uji linieritas terlebih dahulu terhadap data yang digunakan. Hasil dari uji linieritas diperoleh nilai *P-Value* sebesar $3,826e^{-06}$. Nilai tersebut kurang dari taraf signifikan yang digunakan yaitu 0,05, sehingga dapat disimpulkan bahwa data jumlah produksi minyak bumi di *platform* “MK” tahun 2015 tidak linier dan cocok dimodelkan menggunakan *neural network*.

Langkah awal dalam melakukan pemodelan dengan *neural network* adalah menentukan input, jumlah neuron pada *hidden layer*, dan fungsi aktivasi apa yang digunakan. *Input* yang digunakan dalam *neural network* berdasarkan pada model ARIMA terbaik. Model ARIMA terbaik yang telah diperoleh sebelumnya adalah ARIMA (0,1,2), maka *input neural network* yang digunakan merupakan jumlah lag yang keluar dari plot PACF (Gambar 4.7) yaitu lag 1, 2, dan 3. Jumlah neuron yang digunakan pada *hidden layer* mulai dari 1 hingga 10. Sebelum melakukan pemodelan dengan *neural network* data perlu dilakukan standarisasi terlebih dulu, dengan rumus yang digunakan sebagai berikut.

$$Z_t = \frac{Y_t - \bar{Y}}{S_y}$$


Data yang digunakan untuk memodelkan produksi minyak bumi dapat dilihat pada Lampiran 1. Model *neural network* dengan beberapa neuron pada *hidden layer* yang berbeda menghasilkan nilai RMSE yang beragam. Hasil dari pemodelan menggunakan *neural network* dapat dilihat pada Tabel 4.9.

Berdasarkan hasil dari nilai RMSE dengan menggunakan *neural network* pada data *out sample* yang ditunjukkan pada Tabel 4.9, diketahui bahwa nilai RMSE yang terkecil pada data *out sample* terdapat pada neuron 5. Sehingga model terbaik dari *neural network* yang terpilih adalah model dengan 5 neuron. Hasil analisis data jumlah produksi minyak bumi menggunakan *neural network* dapat dilihat pada Lampiran 13.

Tabel 4.9 Pemodelan Metode *Neural Network*
Data Jumlah Produksi Minyak Bumi

Jumlah Neuron	RMSE <i>In sample</i>	RMSE <i>Out sample</i>
1	278,4082	94,83983
2	265,4629	86,56403
3	270,5493	92,77158
4	264,4966	124,6386
5	271,8982	70,83726
6	257,217	111,2526
7	254,8293	171,2617
8	243,5046	134,5891
9	276,5005	96,2848
10	274,8766	87,45966

Arsitektur model *neural network* dengan 5 neuron dapat dilihat pada Gambar 4.8.



Gambar 4.8 Arsitektur *Neural Network* 5 Neuron
Data Jumlah Produksi Minyak Bumi

Arsitektur jaringan model *Neural Network* dapat dimodelkan sesuai dengan fungsi aktivasi sigmoid pada *hidden layer* dan fungsi linier pada *output*. Persamaan matematik yang didapatkan berdasarkan model *Neural Network* 5 neuron adalah sebagai berikut.

$$\hat{Z}_t = 0,995 - 2,266H(1,1)_t - 0,544H(1,2)_t - 0,289H(1,3)_t + 0,481H(1,4)_t + 1,356H(1,5)_t$$

$$H(1,1)_t = \frac{1}{1 + \exp - (0,802 - 1,933Z_{t-1} + 0,449Z_{t-2} + 0,116Z_{t-3} + 0,237Z_{t-4})}$$

$$H(1,2)_t = \frac{1}{1 + \exp - (-0,096 - 0,353Z_{t-1} - 0,483Z_{t-2} + 0,370Z_{t-3} - 0,378Z_{t-4})}$$

$$H(1,3)_t = \frac{1}{1 + \exp - (0,101 - 0,179Z_{t-1} - 0,311Z_{t-2} - 0,226Z_{t-3} - 0,443Z_{t-4})}$$

$$H(1,4)_t = \frac{1}{1 + \exp - (0,017 + 0,225Z_{t-1} + 0,222Z_{t-2} - 0,296Z_{t-3} + 0,359Z_{t-4})}$$

$$H(1,5)_t = \frac{1}{1 + \exp(-(-0,090 - 0,137Z_{t-1} - 0,047Z_{t-2} + 0,646Z_{t-3} + 0,190Z_{t-4}))}$$

4.2.3 Pemodelan Produksi Minyak Bumi dengan Hibrida ARIMA-Neural Network

Pemodelan jumlah produksi minyak bumi yang terakhir menggunakan metode Hibrida ARIMA-*neural network*. Metode ini merupakan metode gabungan dari dua model, yaitu model linier berupa ARIMA dan model non linier yaitu pemodelan residual ARIMA dengan metode *neural network*. Residual yang dimodelkan dengan *neural network* adalah model terbaik yang sudah terpilih pada metode ARIMA sebelumnya yaitu ARIMA (0,1,2), sehingga digunakan *input* berdasarkan jumlah lag PACF yang keluar pada model ARIMA terbaik (Gambar 4.7). Data yang digunakan merupakan data residual dari model ARIMA terpilih yang terdapat pada Lampiran 7. Sama dengan pemodelan menggunakan *neural network*, pemodelan menggunakan metode hibrida ini juga menggunakan jumlah neuron pada *hidden layer* yang berbeda yaitu mulai 1 hingga 10. Hasil dari pemodelan dengan metode hibrida ARIMA-*neural network* dapat dilihat pada Tabel 4.10.

Tabel 4.10 Pemodelan Metode Hibrida Data Jumlah Produksi Minyak Bumi

Jumlah Neuron	RMSE In sample	RMSE Out sample
1	71,55113	47,0244
2	71,56442	46,88192
3	71,50716	47,42676
4	71,424848	47,37643
5	71,38143	47,0355
6	71,44538	47,41358
7	71,47045	46,81031
8	71,43854	47,19942
9	65,54002	51,88179
10	66,66538	46,10634

Berdasarkan hasil pemodelan menggunakan metode hibrida ARIMA-*neural network*, diperoleh nilai RMSE *out sample* yang paling kecil yaitu pada jumlah neuron 10. Sehingga model yang dipilih adalah model hibrida dengan 10 neuron. Hasil analisis selengkapnya terdapat pada Lampiran 15. Berikut persamaan matematik yang diperoleh dari model hibrida ARIMA-*neural network* 10 neuron.

$$\begin{aligned}\hat{N}_t = & -0,164 + 1,768H(1,1)_t - 0,859H(1,2)_t + 0,499H(1,3)_t - 1,198H(1,4)_t \\ & + 1,697H(1,5)_t + 1,097H(1,6)_t - 0,041H(1,7)_t - 1,225H(1,8)_t \\ & + 0,241H(1,9)_t - 1,525H(1,10)_t\end{aligned}$$

$$H(1,1)_t = \frac{1}{1 + \exp - (-1,724 - 2,857N_{t-1} - 1,959N_{t-2} + 2,585N_{t-3} + 3,042N_{t-4})}$$

$$H(1,2)_t = \frac{1}{1 + \exp - (-0,444 - 0,245N_{t-1} - 0,150N_{t-2} + 0,443N_{t-3} + 0,205N_{t-4})}$$

$$H(1,3)_t = \frac{1}{1 + \exp - (0,431 - 0,849N_{t-1} + 0,022N_{t-2} - 0,047N_{t-3} + 1,751N_{t-4})}$$

$$H(1,4)_t = \frac{1}{1 + \exp - (0,748 + 2,096N_{t-1} + 0,416N_{t-2} + 0,222N_{t-3} + 0,528N_{t-4})}$$

$$H(1,5)_t = \frac{1}{1 + \exp - (1,660 + 1,487N_{t-1} + 1,666N_{t-2} - 0,429N_{t-3} - 1,052N_{t-4})}$$

$$H(1,6)_t = \frac{1}{1 + \exp - (0,744 - 0,612N_{t-1} - 1,514N_{t-2} + 1,686N_{t-3} - 2,368N_{t-4})}$$

$$H(1,7)_t = \frac{1}{1 + \exp - (-0,207 - 0,404N_{t-1} - 0,169N_{t-2} + 0,502N_{t-3} + 0,644N_{t-4})}$$

$$H(1,8)_t = \frac{1}{1 + \exp - (-0,833 - 1,236N_{t-1} - 0,893N_{t-2} + 1,016N_{t-3} + 0,617N_{t-4})}$$

$$H(1,9)_t = \frac{1}{1 + \exp - (0,207 - 0,266N_{t-1} - 0,347N_{t-2} - 0,024N_{t-3} - 0,211N_{t-4})}$$

$$H(1,10)_t = \frac{1}{1 + \exp - (1,782 - 1,321N_{t-1} + 0,078N_{t-2} + 0,479N_{t-3} - 1,192N_{t-4})}$$

Model hibrida dalam penelitian ini merupakan gabungan dari metode ARIMA dan *neural network*, sehingga secara umum kombinasi model *time series* hibrida adalah $Y_t = L_t + N_t$, dimana L_t menunjukkan komponen linier (model ARIMA) dan N_t merupakan komponen non linier (model NN residual). Jadi model hibrida ARIMA-NN yang terbentuk adalah sebagai berikut.

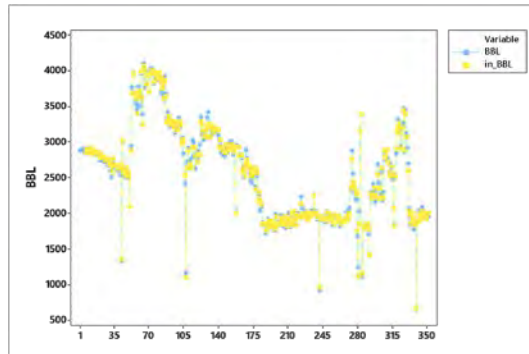
$$\hat{Y}_t = \hat{L}_t + \hat{N}_t$$

Setelah dilakukan pemodelan pada data jumlah produksi minyak bumi menggunakan 3 metode, maka dapat dibandingkan berdasarkan nilai RMSE pada data *out sample*. Hasil perbandingan nilai RMSE berdasarkan ketiga metode dapat dilihat pada Tabel 4.11.

Tabel 4.11 Perbandingan Hasil Metode Terbaik Data Produksi Minyak Bumi


Metode	RMSE <i>In sample</i>	RMSE <i>Out sample</i>
ARIMA	71,47089	48,91872
<i>Neural Network</i>	271,8982	70,83726
Hibrida	66,66538	46,10634

Berdasarkan hasil dari perbandingan ketiga metode di atas dapat dilihat bahwa nilai RMSE pada data *in sample* dan *out sample* menunjukkan bahwa nilai RMSE terkecil terdapat pada metode hibrida ARIMA- *neural network*. Jadi model yang dipilih untuk meramalkan periode selanjutnya adalah model hibrida ARIMA- *neural network*. Plot akurasi antara fit dengan data asli *in sample* dapat dilihat pada Gambar 4.9.



Gambar 4.9 Plot Akurasi *In Sample* Data Jumlah Produksi Minyak Bumi

Berdasarkan Gambar 4.9 diketahui bahwa hasil dari pemodelan menggunakan metode hibrida *ARIMA-neural network* memberikan hasil yang sangat mendekati pola data aslinya. Untuk plot akurasi antara fit dengan data asli *out sample* dapat dilihat pada Gambar 4.10.



Gambar 4.10 Plot Akurasi *Out Sample* Data Jumlah Produksi Minyak Bumi

Berdasarkan gambar 4.10 dapat dilihat bahwa menggunakan metode hibrida *ARIMA-neural network* pola data fit *out sample* yang terbentuk tidak dapat mengikuti data asli. Namun tetap dipilih metode hibrida *ARIMA-neural network* karena menghasilkan nilai RMSE yang paling kecil.

Hasil dari ramalan jumlah produksi minyak bumi untuk 14 hari selanjutnya dapat dilihat pada Tabel 4.12.

Tabel 4.12 Ramalan Produksi Minyak Bumi

Hari	Ramalan	Hari	Ramalan
01/01/2016	1926,012	08/01/2016	1961,408
02/01/2016	1962,49	09/01/2016	1961,396
03/01/2016	1962,369	10/01/2016	1961,395
04/01/2016	1961,015	11/01/2016	1961,398
05/01/2016	1961,435	12/01/2016	1961,396
06/01/2016	1961,415	13/01/2016	1961,397
07/01/2016	1961,361	14/01/2016	1961,397


4.3 Pemodelan Produksi Gas Bumi

Analisis selanjutnya adalah memodelkan data jumlah produksi gas bumi di *platform* “MK”. Sama seperti sebelumnya, dalam memodelkan produksi gas bumi ini dilakukan dengan tiga metode, yaitu ARIMA, *neural network*, dan hibrida ARIMA-*neural network*. Sebelum melakukan memodelkan data produksi gas, dilakukan pemotongan data untuk membedakan data *in sample* dan *out sample*. Data *out sample* yang digunakan sebanyak 14 hari terakhir.

4.3.1 Pemodelan Produksi Gas Bumi Dengan ARIMA

Langkah pertama dalam melakukan pemodelan menggunakan ARIMA adalah melihat pola data yang akan dimodelkan terlebih dahulu. Data yang digunakan dalam time series plot adalah data jumlah produksi gas bumi tahun 2015 yang dapat dilihat pada Lampiran 2, dan hasil time series plot yang diperoleh dapat dilihat pada Gambar 4.11.


Berdasarkan hasil time series plot pada Gambar 4.11, diketahui bahwa pola data dari jumlah produksi gas bumi selama tahun 2015 berfluktuatif. Banyak jumlah produksi yang menurun drastis, diduga adanya perbaikan pada sumur. Selain itu, berdasarkan gambar di atas diduga data jumlah produksi gas bumi di *platform* “MK” selama tahun 2015 belum stasioner.



Gambar 4.11 Time Series Plot Gas Bumi

a. Stasioneritas Data Produksi Gas Bumi

Pengecekan stasioneritas data yang pertama adalah melihat apakah data produksi gas bumi selama tahun 2015 sudah stasioner terhadap varians atau belum. Cara yang digunakan adalah dengan melihat transformasi box-cox. Hasil transformasi box-cox yang diperoleh dapat dilihat pada Gambar 4.12.




Gambar 4.12 Transformasi Box-Cox Gas Bumi

Berdasarkan Gambar 4.12 diketahui bahwa nilai *rounded value* atau nilai lambda (2,00) sudah berada di antara nilai *lower* (1,64) dan *upper* (2,32). Artinya data jumlah produksi gas bumi selama tahun 2015 sudah stasioner dalam varians.

Selanjutnya melakukan pengecekan stasioneritas data produksi gas berdasarkan mean. Jika dilihat pada hasil box-plot

pada Gambar 4.2 sebelumnya, diduga data produksi gas bumi belum stasioner dalam mean. Untuk memastikan dapat dilihat dari plot ACF. Gambar 4.13 menunjukkan plot ACF dari data produksi gas bumi.




Gambar 4.13 Plot ACF Gas Bumi

Melihat dari hasil plot ACF data produksi gas bumi pada Gambar 4.13, diketahui pola ACF turun secara lambat. Artinya adalah data jumlah produksi gas bumi tahun 2015 terbukti belum stasioner dalam mean. Untuk membuat stasioner dalam mean perlu dilakukan *differencing* sebanyak satu kali.

b. Pendugaan Model ARIMA Data Produksi Gas Bumi


Setelah dipastikan data produksi gas bumi sudah stasioner dalam varians dan mean, selanjutnya melakukan pendugaan model dengan melihat plot ACF dan PACF. Karena tadi data produksi gas bumi mengalami *differencing* sebanyak 1 kali, maka untuk menduga model data yang digunakan adalah data hasil *differencing*. Gambar 4.14 menunjukkan plot ACF dari data produksi gas bumi yang sudah stasioner. Nilai dari setiap lag ACF dapat dilihat pada Lampiran 8.



Gambar 4.14 Plot ACF Gas Bumi Sudah Stasioner

Berdasarkan plot ACF pada Gambar 4.14, diketahui bahwa pola plot ACF tersebut *cuts off* setelah lag pertama. Untuk dapat menduga model yang tepat, selanjutnya melihat plot PACF dari data produksi gas bumi yang sudah stasioner. Plot PACF yang diperoleh dapat dilihat pada Gambar 4.15.

Melihat hasil plot PACF pada Gambar 4.15, diketahui bahwa pola plot PACF tersebut adalah *dies down* dengan 3 lag pertama yang keluar dari batas. Untuk lag selanjutnya sudah berada di dalam batas atau mendekati 0. Nilai dari PACF terdapat di Lampiran 9.



Gambar 4.15 Plot PACF Gas Bumi Sudah Stasioner

Setelah melihat hasil dari plot ACF dan PACF selanjutnya menduga model yang mungkin terbentuk. Model tersebut adalah

ARIMA (0,1,1), ARIMA (1,1,1), ARIMA (2,1,1), dan ARIMA (3,1,1).

c. Uji Signifikansi Parameter Data Produksi Gas Bumi

Analisis selanjutnya adalah melakukan uji signifikansi parameter dari model-model dugaan yang sudah didapatkan sebelumnya. Data yang digunakan dalam melakukan uji signifikansi parameter adalah data *in sample* produksi gas bumi yang dapat dilihat pada Lampiran 2. Tabel 4.13 berikut merupakan hasil yang diperoleh dari pengujian signifikansi parameter.

Tabel 4.13 Uji Signifikansi Parameter Data Produksi Gas Bumi

Model	Parameter	Estimasi	P-Value	Keterangan
ARIMA (0,1,1)	θ_1	0,56783	<0,0001	Signifikan
ARIMA (1,1,1)	ϕ_1	0,27275	0,0012	Signifikan
	θ_1	0,76141	<0,0001	Signifikan
ARIMA (2,1,1)	ϕ_1	0,28564	0,0016	Signifikan
	ϕ_2	0,01870	0,7898	Tidak
	θ_1	0,77679	<0,0001	Signifikan
ARIMA (3,1,1)	ϕ_1	0,27071	0,0137	Signifikan
	ϕ_2	0,01254	0,8636	Tidak
	ϕ_3	-0,01160	0,8677	Tidak
	θ_1	0,76177	<0,0001	Signifikan

Berdasarkan hasil dari uji signifikansi parameter, diketahui bahwa model yang memiliki parameter yang signifikan semua adalah model ARIMA (0,1,1) dan ARIMA (1,1,1). Selanjutnya dilakukan uji kesesuaian model pada model dugaan yang signifikan.

d. Uji Kesesuaian Model Data Produksi Gas Bumi

Uji kesesuaian model digunakan untuk menguji model dugaan ARIMA sudah memenuhi asumsi yang dibutuhkan atau belum. asumsi yang dibutuhkan adalah *white noise* dan berdistribusi normal. Data yang digunakan dapat dilihat pada Lampiran 2 dan hasil yang diperoleh dapat dilihat pada Tabel 4.14, nilai yang tertera di tabel adalah P-Value .

Tabel 4.14 Uji Kesesuaian Model Data Produksi Gas Bumi

Lag <i>White Noise</i>	ARIMA (0,1,1)		ARIMA (1,1,1)	
	P-Value	Keterangan	P-Value	Keterangan
Lag 6	0,1305	<i>White Noise</i>	0,9539	<i>White Noise</i>
Lag 12	0,1184	<i>White Noise</i>	0,7385	<i>White Noise</i>
Lag 18	0,3244	<i>White Noise</i>	0,949	<i>White Noise</i>
Lag 24	0,6574	<i>White Noise</i>	0,9942	<i>White Noise</i>
Lag 30	0,8018	<i>White Noise</i>	0,9984	<i>White Noise</i>
Lag 36	0,8411	<i>White Noise</i>	0,9987	<i>White Noise</i>
Lag 42	0,8697	<i>White Noise</i>	0,999	<i>White Noise</i>
Lag 48	0,9207	<i>White Noise</i>	0,9997	<i>White Noise</i>

Tabel 4.14 menunjukkan bahwa dengan taraf signifikan yang digunakan 5% kedua dugaan model yaitu ARIMA (0,1,1) dan ARIMA (1,1,1) telah memenuhi asumsi *white noise*. Namun dalam uji distribusi normal diperoleh nilai P-Value kedua model masih kurang dari 0,001, sehingga dapat disimpulkan bahwa kedua model belum memenuhi asumsi berdistribusi normal. Untuk menangani hal ini diperlukan deteksi *outlier* agar kedua model tersebut dapat memenuhi asumsi.

Langkah pertama dalam deteksi *outlier* adalah melakukan uji signifikansi parameter dengan memasukkan data outlier. Hasil dari uji signifikansi parameter model ARIMA (0,1,1) dengan data outlier dapat dilihat pada Tabel 4.15.

Tabel 4.15 Uji Signifikansi Parameter Model ARIMA (0,1,1) Deteksi *Outlier*
Data Produksi Gas Bumi

Parameter	Estimasi	P-Value	Parameter	Estimasi	P-Value
θ_1	0,56541	<0,0001	ω_{325}	798,67077	<0,0001
ω_{107}	-3025,3	<0,0001	ω_{307}	933,06142	<0,0001
ω_{42}	-3045,5	<0,0001	ω_{190}	-598,28755	0,0005
ω_{339}	-2823,9	<0,0001	ω_{105}	-612,45971	0,0003
ω_{281}	-1894,6	<0,0001	ω_{65}	548,21766	0,0008
ω_{280}	-1696,3	<0,0001	ω_{155}	-465,4939	0,0052
ω_{242}	-1467,2	<0,0001	ω_{222}	-472,41132	0,0037

Tabel 4.15 (Lanjutan)

Parameter	Estimasi	P-Value	Parameter	Estimasi	P-Value
ω_{117}	-920,60592	<0,0001	ω_{10}	366,60954	0,0242
ω_{312}	-1018,3	<0,0001	ω_{210}	-594,76994	0,0007
ω_{141}	-801,97721	<0,0001	ω_{261}	757,06719	<0,0001
ω_{315}	-753,23722	0,0007	ω_{32}	471,42782	0,0166
ω_{182}	-540,81666	0,0023	ω_{262}	654,34469	0,0003
ω_{274}	1505,7	<0,0001	ω_{314}	-495,237	0,015
ω_{52}	1673	<0,0001	ω_{49}	823,23122	<0,0001
ω_{55}	-1505,7	<0,0001	ω_{157}	-4706,3	<0,0001
ω_{114}	1113,9	<0,0001	ω_{166}	-665,25736	0,0002
ω_{32}	-1347,3	<0,0001	ω_{300}	751,74629	<0,0001
ω_{316}	-1691,5	<0,0001	ω_{304}	672,87641	0,0002
ω_{109}	1192,9	<0,0001	ω_{115}	479,13752	0,0087
ω_{196}	-906,37648	<0,0001	ω_{301}	436,39371	0,0149
ω_{320}	860,68959	<0,0001	ω_{159}	-686,32628	<0,0001
ω_{285}	-852,30673	<0,0001	ω_{185}	540,96897	0,0013
ω_{331}	-955,15592	<0,0001	ω_{333}	465,6937	0,0067
ω_{294}	742,71002	<0,0001	ω_{188}	-468,92125	0,0071

Berdasarkan Tabel 4.15 diketahui bahwa parameter θ_1 dengan 47 outlier yang terdeteksi sudah signifikan berpengaruh terhadap model dengan taraf signifikan yang digunakan sebesar 5%. Langkah selanjutnya dalam deteksi *outlier* adalah melakukan uji kesesuaian model, untuk melihat apakah residual sudah memenuhi asumsi *white noise* dan berdistribusi normal setelah mendeteksi *outlier*. Hasil dari uji kesesuaian model dapat dilihat pada Tabel 4.16.

Tabel 4.16 Uji Kesesuaian Model ARIMA (0,1,1)
Deteksi *Outlier* Data Produksi Gas Bumi

White Noise	P-Value	Keterangan
Lag 6	0,1295	Signifikan
Lag 12	0,1103	Signifikan
Lag 18	0,2716	Signifikan
Lag 30	0,2060	Signifikan
Lag 24	0,3521	Signifikan
Lag 36	0,3370	Signifikan
Lag 42	0,4001	Signifikan
Lag 48	0,3546	Signifikan

Melihat hasil dari uji kesesuaian model pada tabel di atas, dengan taraf signifikansi 5% diketahui bahwa residual dari model ARIMA (0,1,1) sudah memenuhi asumsi *white noise*. Begitu pula setelah melakukan uji distribusi normal, diperoleh nilai P-Value sebesar 0,0918. Artinya residual model ARIMA (0,1,1) memenuhi asumsi berdistribusi normal.

Selanjutnya melakukan deteksi *outlier* untuk model ARIMA (1,1,1) dengan langkah yang sama dengan sebelumnya, yaitu pertama melakukan uji signifikansi parameter. Tabel 4.17 berikut menunjukkan uji signifikansi parameter pada model ARIMA (1,1,1).

Tabel 4.17 Uji Signifikansi Parameter Model ARIMA (1,1,1)
Deteksi *Outlier* Data Produksi Gas Bumi

Parameter	Estimasi	P-Value	Parameter	Estimasi	P-Value
θ_1	0,88073	<0,0001	ω_{190}	-671,21534	<0,0001
ϕ_1	0,41492	<0,0001	ω_{105}	-529,41893	0,0004
ω_{107}	-2992,3	<0,0001	ω_{65}	456,99466	0,0014
ω_{42}	-3105,3	<0,0001	ω_{155}	-505,26302	0,0008
ω_{339}	-2804,6	<0,0001	ω_{222}	-481,90191	0,0003
ω_{281}	-1877,4	<0,0001	ω_{10}	398,0249	0,0026
ω_{280}	-1627,3	<0,0001	ω_{210}	-605,91062	0,0002
ω_{242}	-1526,5	<0,0001	ω_{261}	717,90996	<0,0001

Tabel 4.17 (Lanjutan)

Parameter	Estimasi	P-Value	Parameter	Estimasi	P-Value
ω_{117}	-928,84616	<0,0001	ω_{32}	426,91626	0,0166
ω_{312}	-929,10022	<0,0001	ω_{262}	630,8877	0,0003
ω_{141}	-742,05313	<0,0001	ω_{314}	-415,67337	0,0286
ω_{315}	-689,68382	0,0014	ω_{49}	773,90025	<0,0001
ω_{182}	-470,3028	0,0039	ω_{157}	-4659	<0,0001
ω_{274}	1346,5	<0,0001	ω_{166}	-615,68137	0,0002
ω_{52}	1598,2	<0,0001	ω_{300}	799,54482	<0,0001
ω_{55}	-1559,1	<0,0001	ω_{304}	646,13123	<0,0001
ω_{114}	1109,3	<0,0001	ω_{115}	433,30801	0,0075
ω_{32}	-1321,5	<0,0001	ω_{301}	471,12081	0,0073
ω_{316}	-1541,2	<0,0001	ω_{159}	-747,29781	<0,0001
ω_{109}	1051,2	<0,0001	ω_{185}	514,96623	0,0011
ω_{196}	-978,68404	<0,0001	ω_{333}	391,94943	0,0171
ω_{320}	688,35664	<0,0001	ω_{188}	-400,16685	0,0228
ω_{285}	-887,20043	<0,0001	ω_{61}	-628,50527	0,0001
ω_{331}	-959,88743	<0,0001	ω_{59}	454,2227	0,0036
ω_{294}	597,1384	<0,0001	ω_{310}	-464,50306	0,0055
ω_{325}	741,93394	<0,0001	ω_{171}	-353,86559	0,0087
ω_{307}	1041,2	<0,0001	ω_{275}	382,19978	0,0185

Tabel 4.17 menunjukkan bahwa menggunakan taraf signifikansi sebesar 5% nilai parameter dari model ARIMA (1,1,1) sudah signifikan semua, termasuk juga parameter *outlier* yang terdeteksi. Selanjutnya melakukan uji kesesuaian model pada model ARIMA (1,1,1) untuk melihat apakah residual sudah memenuhi asumsi *white noise* dan berdistribusi normal setelah dilakukan deteksi *outlier*. Hasil dari uji kesesuaian model dapat dilihat pada Tabel 4.18.

Tabel 4.18 Uji Kesesuaian Model ARIMA (1,1,1)
Deteksi *Outlier* Data Produksi Gas Bumi

White Noise	P-Value	Keterangan
Lag 6	0,3842	Signifikan
Lag 12	0,2139	Signifikan
Lag 18	0,2481	Signifikan
Lag 24	0,3573	Signifikan
Lag 30	0,1674	Signifikan
Lag 36	0,2640	Signifikan
Lag 42	0,2876	Signifikan
Lag 48	0,1421	Signifikan

Melihat dari hasil uji kesesuaian model ARIMA (1,1,1) di atas dapat disimpulkan bahwa setelah dilakukan deteksi outlier dengan menggunakan taraf signifikan sebesar 5%, residual sudah memenuhi asumsi white noise. Setelah dilakukan uji asumsi berdistribusi normal diperoleh nilai *P-Value* sebesar 0,0940, sehingga dapat disimpulkan bahwa residual model ARIMA (1,1,1) berdistribusi normal.

Selanjutnya untuk menentukan model ARIMA yang terpilih dilakukan pemilihan model terbaik berdasarkan kriteria yang sudah ditentukan.

e. Pemilihan Model Terbaik Data Produksi Gas Bumi

Pemilihan model terbaik dilakukan untuk memilih model yang terbaik diantara model dugaan yang sudah memenuhi semua asumsi. Terdapat beberapa kriteria dalam pemilihan model terbaik, namun pada penelitian ini kriteria yang digunakan adalah RMSE sehingga dipilih model ARIMA dengan nilai RMSE paling kecil. Nilai RMSE dari pemilihan model terbaik dapat dilihat pada Tabel 4.19, dengan data yang digunakan yaitu data in sample yang terdapat pada Lampiran 2.

Tabel 4.19 Pemilihan Model Terbaik Data Produksi Gas Bumi

Model	RMSE	
	In sample	Out Sample
ARIMA (0,1,1)	181,772	198,2455
ARIMA (1,1,1)	167,7969	195,5305

Berdasarkan hasil dari pemilihan model terbaik di atas, diketahui bahwa nilai RMSE *out sample* yang paling kecil terdapat pada model ARIMA (1,1,1). Sehingga dipilih model ARIMA (1,1,1) dengan deteksi *outlier* sebagai model terbaik. Hasil analisis menggunakan ARIMA pada data jumlah produksi gas bumi dapat dilihat pada Lampiran 12. Persamaan matematik dari model ARIMA (1,1,1) adalah sebagai berikut.

$$\begin{aligned}
Z_t = & 1,41492 Z_{t-1} + 0,41492 Z_{t-2} - 0,88073 a_{t-1} + a_t - 2992,3I_t^{107} \\
& - 3105,3I_t^{42} - 2804,6I_t^{339} - 1877,4I_t^{281} - 1627,3I_t^{280} - 1526,5I_t^{242} \\
& - 928,8I_t^{117} - 929,1I_t^{312} - 742,1I_t^{114} - 689,7I_t^{315} - 470,3I_t^{182} + \frac{1346,5}{(1-B)} I_t^{274} \\
& + \frac{1598,2}{(1-B)} I_t^{52} - \frac{1559,1}{(1-B)} I_t^{55} + \frac{1109,3}{(1-B)} I_t^{114} - \frac{1321,5}{(1-B)} I_t^{32} - \frac{1541,2}{(1-B)} I_t^{316} \\
& + \frac{1051,2}{(1-B)} I_t^{109} - \frac{978,7}{(1-B)} I_t^{196} + \frac{688,4}{(1-B)} I_t^{320} - \frac{887,2}{(1-B)} I_t^{285} - \frac{959,9}{(1-B)} I_t^{331} \\
& + \frac{597,1}{(1-B)} I_t^{294} + \frac{741,9}{(1-B)} I_t^{325} + \frac{1041,2}{(1-B)} I_t^{307} - \frac{671,1}{(1-B)} I_t^{190} - \frac{529,4}{(1-B)} I_t^{105} \\
& + \frac{457,0}{(1-B)} I_t^{65} - \frac{505,3}{(1-B)} I_t^{155} - \frac{481,9}{(1-B)} I_t^{222} + \frac{398,0}{(1-B)} I_t^{10} - 605,9I_t^{210} + 717,9I_t^{261} \\
& + 426,9I_t^{32} + 630,9I_t^{262} - 415,7I_t^{314} + 773,9I_t^{49} - 4659,0I_t^{157} - 615,7I_t^{166} \\
& + 799,5I_t^{300} + 646,1I_t^{304} + 433,3I_t^{115} + 471,1I_t^{301} - \frac{747,3}{(1-B)} I_t^{159} + \frac{515,0}{(1-B)} I_t^{185} \\
& + \frac{391,9}{(1-B)} I_t^{333} - \frac{400,2}{(1-B)} I_t^{188} - 628,5I_t^{61} + \frac{454,5}{(1-B)} I_t^{59} - \frac{464,5}{(1-B)} I_t^{310} \\
& - \frac{353,9}{(1-B)} I_t^{171} + 382,2I_t^{275}
\end{aligned}$$

Model tersebut memiliki arti bahwa, jumlah produksi gas bumi pada hari ini, berhubungan dengan jumlah produksi minyak bumi pada 1 dan 2 hari sebelumnya.

4.3.2 Pemodelan Produksi Gas Bumi Dengan *Neural Network*

Pemodelan jumlah produksi gas bumi selanjutnya menggunakan metode *neural network*. Sama seperti pemodelan pada produksi minyak bumi, sebelum melakukan pemodelan menggunakan *neural network* sebaiknya melakukan uji linieritas data terlebih dahulu dengan uji terasvirta. Setelah melakukan uji terasvirta diperoleh nilai *P-Value* kurang dari $2,2e^{-16}$, artinya adalah data jumlah produksi gas bumi pada platform “MK” di PT “X” tahun 2015 tidak linier sehingga cocok untuk dimodelkan menggunakan *neural network*.

Langkah awal dalam melakukan pemodelan menggunakan *neural network* adalah menentukan *input*, menentukan jumlah neuron pada *hidden layer*, dan fungsi aktivasi yang digunakan. Input yang digunakan pada *neural network* adalah model ARIMA yang terpilih sebelumnya. Model ARIMA yang terpilih adalah ARIMA (1,1,1), sehingga *input* yang digunakan berdasarkan pada jumlah orde AR saja, yaitu Y_{t-1} . Selain itu karena ada efek *differencing* maka ditambahkan satu *input* lagi, yaitu Y_{t-2} . Jumlah neuron yang digunakan mulai dari 1 sampai 10, sehingga diperoleh nilai RMSE yang berbeda-beda dari setiap jumlah neuron. Sebelum melakukan analisis dengan *neural network*, data harus dilakukan *pre-processing* terlebih dahulu. *Pre-processing* yang digunakan sama dengan data minyak bumi, yaitu standarisasi. Hasil dari pemodelan menggunakan *neural network* dapat dilihat pada Tabel 4.20, dengan data yang digunakan terdapat pada Lampiran 2.


Tabel 4.20 Pemodelan *Neural Network* Data Produksi Gas Bumi

Jumlah Neuron	RMSE In sample	RMSE Out sample
1	582,9493	192,7433
2	584,4298	190,8954
3	531,9169	268,2365

Tabel 4.20 (Lanjutan)

Jumlah Neuron	RMSE In sample	RMSE Out sample
4	531,0319	261,5619
5	531,521	294,2941
6	525,9528	216,2174
7	525,0536	340,4683
8	528,0992	284,0333
9	524,9976	282,872
10	539,7337	197,3947

Berdasarkan hasil dari pemodelan menggunakan *neural network*, terlihat pada nilai RMSE *in sample* yang paling kecil terdapat pada neuron 9. Namun berbeda dengan RMSE pada *out sample* yang paling kecil terdapat pada jumlah neuron 2. Sehingga dipilih model *neural network* dengan neuron 2. Hasil analisis menggunakan *neural network* dapat dilihat pada Lampiran 14. Berikut arsitektur dari model NN jumlah neuron 2.

**Gambar 4.16** Arsitektur *Neural Network* 2 Neuron Produksi Gas Bumi

Arsitektur jaringan model *neural network* dapat dimodelkan sesuai dengan fungsi aktivasi sigmoid pada *hidden layer* dan fungsi linier pada output. Berikut persamaan matematik dari model NN 2 neuron.

$$\hat{Z}_t = 0,344 + 1,743H(1,1)_t - 1,860H(1,2)_t$$

$$H(1,1)_t = \frac{1}{1 + \exp - (-0,408 + 1,137Z_{t-1} + 0,104Z_{t-2})}$$

$$H(1,2)_t = \frac{1}{1 + \exp - (0,462 - 1,083Z_{t-1} - 0,254Z_{t-2})}$$

4.3.3 Pemodelan Produksi Gas Bumi Dengan Hibrida ARIMA – *Neural Network*

Pemodelan data jumlah produksi gas bumi yang terakhir dilakukan menggunakan metode gabungan, yaitu hibrida ARIMA-*neural network*. *Input* yang digunakan dalam metode hibrida ini adalah nilai residual dari model ARIMA yang terpilih sebelumnya. Sama seperti metode *neural network*, metode hibrida juga dilakukan dengan jumlah neuron mulai dari 1 sampai 10. Hasil yang diperoleh dari metode hibrida ARIMA-*neural network* dapat dilihat pada Tabel 4.21 dengan data yang digunakan terdapat pada Lampiran 10.

Tabel 4.21 Pemodelan Hibrida ARIMA- *Neural Network* Produksi Gas Bumi

Jumlah Neuron	RMSE In sample	RMSE Out sample
1	167,291	195,4128
2	167,114	195,4707
3	167,2037	195,4614
4	167,0955	195,6242
5	167,0705	195,7543
6	167,0881	195,6049
7	167,0786	195,5291
8	167,0291	195,746
9	167,0462	195,5653
10	167,0485	195,5989

Berdasarkan hasil dari pemodelan menggunakan metode gabungan, yaitu hibrida ARIMA-*neural network* nilai RMSE pada *in sample* terdapat pada neuron 8, sedangkan nilai RMSE *out sample* yang paling kecil terdapat pada neuron 1. Sehingga model hibrida ARIMA-*neural network* yang dipilih adalah model dengan 1 neuron. Hasil analisis selengkapnya terdapat pada Lampiran 16. Berikut model matematik dari model hibrida ARIMA-*neural network* 1 neuron.

$$\hat{N}_t = 1,843 - 3,152H(1,1)_t$$


$$H(1,1)_t = \frac{1}{1 + \exp - (0,525 - 1,536N_{t-1} - 0,052N_{t-2})}$$

Setelah melakukan pemodelan menggunakan tiga metode yaitu ARIMA, *neural network*, dan hibrida ARIMA- *neural network* pada data jumlah produksi gas bumi di *platform* “MK” tahun 2015, maka dapat dibandingkan hasilnya menggunakan nilai RMSE yang paling kecil. Perbandingan dari ketiga metode dapat dilihat pada Tabel 4.22.

Tabel 4.22 Perbandingan Model Data Produksi Gas Bumi


Metode	RMSE In sample	RMSE Out sample
ARIMA	167,7969	195,5305
<i>Neural Network</i>	584,4198	190,8954
Hibrida	167,291	195,4128

Hasil perbandingan pada Tabel 4.22, menunjukkan bahwa nilai RMSE pada data *in sample* paling kecil terdapat pada metode hibrida ARIMA- *neural network*. Sedangkan pada data *out sample*, nilai RMSE yang paling kecil terdapat pada metode *neural network*. Sehingga dipilih metode *neural network* untuk meramalkan jumlah produksi gas bumi di *platform* “MK” periode selanjutnya. Plot akurasi antara data fit dengan data *in sample* asli dapat dilihat pada Gambar 4.17.



Gambar 4.17 Plot Akurasi *In Sample* Data Jumlah Produksi Gas Bumi

Dapat dilihat pada Gambar 4.17 bahwa nilai *fit in sample* pada data jumlah produksi gas bumi dapat mengikuti pola data asli menggunakan metode *neural network*. Sedangkan untuk plot akurasi antara fit dengan data *out sample* asli dapat dilihat pada Gambar 4.18.



Gambar 4.18 Plot Akurasi *Out Sample* Data Jumlah Produksi Gas Bumi

Berdasarkan Gambar 4.18 dapat diketahui bahwa pola dari data fit tidak dapat mengikuti pola data *out sample* asli. Data fit membentuk pola yang cenderung konstan selama 14 hari selanjutnya, sedangkan data *out sample* asli memiliki pola fluktuatif.

Hasil dari ramalan produksi gas bumi selama 14 hari selanjutnya dapat dilihat pada Tabel 4.23.

Tabel 4.23 Ramalan Produksi Gas Bumi

Hari	Ramalan	Hari	Ramalan
01/01/2016	4307,41	08/01/2016	4395,976
02/01/2016	4330,388	09/01/2016	4399,163
03/01/2016	4352,917	10/01/2016	4401,516
04/01/2016	4366,928	11/01/2016	4403,264
05/01/2016	4378,023	12/01/2016	4404,56
06/01/2016	4385,823	13/01/2016	4405,523
07/01/2016	4391,693	14/01/2016	4406,239

“Halaman ini sengaja dikosongkan”

Lampiran

Lampiran 1 Data Jumlah Produksi Minyak Bumi Tahun 2015

No	Tanggal	Jumlah (Barel)
1	1 Januari	2878,7
2	2 Januari	2898,5
3	3 Januari	2909,7
4	4 Januari	2883,6
5	5 Januari	2851,7
6	6 Januari	2913,6
7	7 Januari	2874,1
8	8 Januari	2846,2
9	9 Januari	2918,2
10	10 Januari	2863,0
⋮	⋮	⋮
352	18 Desember	1915,0
353	19 Desember	1902,6
354	20 Desember	1890,4
355	21 Desember	1903,5
356	22 Desember	1931,1
357	23 Desember	1962,9
358	24 Desember	1970,0
359	25 Desember	1971,9
360	26 Desember	1983,1
361	27 Desember	1992,3
362	28 Desember	1846,7
363	29 Desember	2001,6
364	30 Desember	1988,4
365	31 Desember	1991,0

Lampiran 2 Data Jumlah Produksi Gas Bumi Tahun 2015

No	Tanggal	Jumlah (mScf)
1	1 Januari	6751
2	2 Januari	6775
3	3 Januari	6810
4	4 Januari	6797
5	5 Januari	6942
6	6 Januari	6973
7	7 Januari	6972
8	8 Januari	6993
9	9 Januari	6673
10	10 Januari	7132
⋮	⋮	⋮
352	18 Desember	4386
353	19 Desember	4676
354	20 Desember	4635
355	21 Desember	4579
356	22 Desember	4506
357	23 Desember	4368
358	24 Desember	4433
359	25 Desember	4407
360	26 Desember	4381
361	27 Desember	4331
362	28 Desember	3840
363	29 Desember	4366
364	30 Desember	4234
365	31 Desember	4252

Lampiran 3 Nilai Box Plot Data Jumlah Produksi Minyak Bumi Tahun 2015

No	Hari	Kuartil Bawah	Median	Kuartil Atas	Min.	Max.
1	Senin	4365,75	5882,50	6996,75	3543,00	8386,00
2	Selasa	4365,75	5910,50	6891,50	3613,00	8351,00
3	Rabu	4283,75	5886,50	6894,00	2761,00	8362,00
4	Kamis	4459,00	5679,00	6870,00	3193,00	8346,00
5	Jumat	4421,00	5808,50	6848,25	3002,00	8209,00
6	Sabtu	4398,25	6008,50	2460,25	1577,00	8718,00
7	Minggu	4583,00	6140,50	6940,75	2568,00	8460,00

Lampiran 4 Nilai Box Plot Data Jumlah Produksi Gas Bumi Tahun 2015

No	Hari	Kuartil Bawah	Median	Kuartil Atas	Min.	Max.
1	Senin	1981,22	2593,70	3008,70	1117,00	3971,40
2	Selasa	2003,65	2672,10	3041,80	1758,60	3979,50
3	Rabu	1977,75	2643,10	2993,60	1338,60	3896,30
4	Kamis	1959,00	2685,10	2926,10	1239,80	3991,10
5	Jumat	1929,33	2600,55	2943,70	1165,30	4107,00
6	Sabtu	2018,13	2593,50	3041,30	649,50	4022,80
7	Minggu	1980,80	2623,90	3158,28	925,00	4014,60

Lampiran 5 Nilai ACF Data Produksi Minyak Bumi Setelah
Differencing

Lag	ACF	T	LBQ
1	-0,267961	-5,01	25,35
2	-0,155570	-2,72	33,92
3	-0,010694	-0,18	33,96
4	-0,000854	-0,01	33,96
5	0,019387	0,33	34,09
6	-0,012416	-0,21	34,15
7	0,072484	1,24	36,03
8	-0,143547	-2,45	43,46
9	0,046277	0,78	44,23
10	0,109596	1,83	48,58
11	-0,087328	-1,45	51,35
12	-0,026740	-0,44	51,61
13	0,017422	0,29	51,72
14	0,016710	0,28	51,83
15	-0,037126	-0,61	52,33
16	0,030707	0,51	52,68
17	-0,002533	-0,04	52,68
18	-0,021053	-0,35	52,85
19	0,016059	0,26	52,94
20	0,004346	0,07	52,95
21	-0,015923	-0,26	53,05
22	0,056712	0,93	54,25
23	-0,102388	-1,68	58,20
24	0,041261	0,67	58,85
25	0,051188	0,83	59,84
26	-0,019840	-0,32	59,99
27	-0,001168	-0,02	59,99
28	-0,002519	-0,04	59,99
29	-0,040556	-0,66	60,62
30	0,027520	0,45	60,92
31	0,013218	0,21	60,98
32	-0,010936	-0,18	61,03
33	-0,042494	-0,69	61,73
34	-0,020936	-0,34	61,90
35	-0,007764	-0,13	61,93
36	0,011565	0,19	61,98
37	0,032844	0,53	62,40
38	-0,003771	-0,06	62,41
39	0,001990	0,03	62,41
40	0,002120	0,03	62,41
41	-0,031769	-0,51	62,81
42	-0,079820	-1,29	65,36

Lampiran 6 Nilai PACF Data Produksi Minyak Bumi Setelah
Differencing

Lag	PACF	T
1	-0,267961	-5,01
2	-0,244962	-4,58
3	-0,146971	-2,75
4	-0,105342	-1,97
5	-0,049238	-0,92
6	-0,047292	-0,88
7	0,058695	1,10
8	-0,124423	-2,33
9	-0,019888	-0,37
10	0,082286	1,54
11	-0,033285	-0,62
12	-0,034393	-0,64
13	-0,012450	-0,23
14	-0,007513	-0,14
15	-0,034277	-0,64
16	-0,005742	-0,11
17	-0,015096	-0,28
18	0,001961	0,04
19	-0,008243	-0,15
20	-0,010549	-0,20
21	-0,007963	-0,15
22	0,067864	1,27
23	-0,094525	-1,77
24	0,003022	0,06
25	0,045755	0,86
26	0,004585	0,09
27	0,016693	0,31
28	0,018855	0,35
29	-0,052806	-0,99
30	0,023775	0,44
31	-0,014694	-0,27
32	-0,016570	-0,31
33	-0,020526	-0,38
34	-0,076051	-1,42
35	-0,087078	-1,63
36	-0,038109	-0,71
37	-0,009603	-0,18
38	-0,009012	-0,17
39	0,023488	0,44
40	0,008802	0,16
41	-0,035234	-0,66
42	-0,124215	-2,32

Lampiran 7 Residual ARIMA Jumlah Produksi Minyak Bumi
Tahun 2015

No	Tanggal	Forecast	Residual
1	1 Januari	2878,70	19,80
2	2 Januari	2894,70	15,00
3	3 Januari	2895,00	-11,40
4	4 Januari	2876,83	-25,13
5	5 Januari	2863,33	50,27
6	6 Januari	2918,96	-44,86
7	7 Januari	2852,70	-6,50
8	8 Januari	2874,22	43,98
9	9 Januari	2913,64	-50,64
10	10 Januari	2846,47	59,93
⋮	⋮	⋮	⋮
352	18 Desember	1840,71	-23,41
353	19 Desember	672,94	-23,44
354	20 Desember	1891,52	-8,52
355	21 Desember	1898,62	131,78
356	22 Desember	2010,20	8,20
357	23 Desember	1938,16	-29,26
358	24 Desember	1909,62	138,78
359	25 Desember	2039,24	51,26
360	26 Desember	1997,82	45,48
361	27 Desember	2003,98	-4,28
362	28 Desember	1973,37	36,03
363	29 Desember	2005,04	-63,84
364	30 Desember	1931,94	53,26
365	31 Desember	2013,09	-64,59

Lampiran 8 Nilai ACF Data Produksi Minyak Bumi Setelah
Differencing

Lag	ACF	T	LBQ
1	-0,338182	-6,33	40,37
2	-0,075178	-1,27	42,37
3	-0,054125	-0,91	43,41
4	0,017918	0,30	43,53
5	-0,015626	-0,26	43,62
6	0,026623	0,45	43,87
7	0,013027	0,22	43,93
8	-0,019315	-0,32	44,06
9	0,009089	0,15	44,09
10	-0,001896	-0,03	44,10
11	-0,051699	-0,87	45,07
12	-0,039112	-0,65	45,62
13	0,027733	0,46	45,91
14	0,019717	0,33	46,05
15	0,012170	0,20	46,10
16	0,025396	0,42	46,34
17	-0,018978	-0,32	46,47
18	-0,015215	-0,25	46,56
19	-0,002766	-0,05	46,56
20	0,014020	0,23	46,64
21	-0,006830	-0,11	46,65
22	0,022484	0,37	46,84
23	-0,033682	-0,56	47,27
24	0,016097	0,27	47,37
25	0,031633	0,53	47,75
26	-0,013114	-0,22	47,81
27	0,017644	0,29	47,93
28	-0,056595	-0,94	49,16
29	0,030854	0,51	49,52
30	-0,028239	-0,47	49,83
31	-0,004360	-0,07	49,84
32	-0,007900	-0,13	49,86
33	0,079644	1,32	52,33
34	-0,011928	-0,20	52,38
35	-0,054051	-0,89	53,52
36	0,036218	0,59	54,04
37	-0,006899	-0,11	54,06
38	-0,027933	-0,46	54,37
39	0,009223	0,15	54,40
40	0,053716	0,88	55,55
41	-0,029492	-0,48	55,89
42	-0,061820	-1,01	57,42

Lampiran 9 Nilai PACF Data Produksi Minyak Bumi Setelah
Differencing

Lag	PACF	T
1	-0,338182	-6,33
2	-0,214022	-4,00
3	-0,186220	-3,48
4	-0,111888	-2,09
5	-0,099672	-1,86
6	-0,043766	-0,82
7	-0,009813	-0,18
8	-0,023196	-0,43
9	-0,001365	-0,03
10	-0,000316	-0,01
11	-0,064202	-1,20
12	-0,110541	-2,07
13	-0,076104	-1,42
14	-0,048928	-0,92
15	-0,024212	-0,45
16	0,021293	0,40
17	0,009495	0,18
18	-0,000778	-0,01
19	-0,006257	-0,12
20	0,002587	0,05
21	-0,011380	-0,21
22	0,008307	0,16
23	-0,040123	-0,75
24	-0,015635	-0,29
25	0,035386	0,66
26	0,024882	0,47
27	0,058521	1,09
28	-0,015791	-0,30
29	0,011801	0,22
30	-0,031145	-0,58
31	-0,048037	-0,90
32	-0,053358	-1,00
33	0,052660	0,99
34	0,048519	0,91
35	-0,013931	-0,26
36	0,043645	0,82
37	0,032873	0,61
38	-0,014857	-0,28
39	-0,018096	-0,34
40	0,033147	0,62
41	-0,002357	-0,04
42	-0,082126	-1,54

Lampiran 10 Residual ARIMA Jumlah Produksi Gas Bumi
Tahun 2015

No	Tanggal	Forecast	Residual
1	1 Januari	6751	24,00
2	2 Januari	6763	46,18
3	3 Januari	6783,85	13,15
4	4 Januari	6780,02	161,98
5	5 Januari	6859,51	113,49
6	6 Januari	6885,91	86,09
7	7 Januari	6895,76	97,24
8	8 Januari	6916,07	-243,07
9	9 Januari	7152,33	-20,33
10	10 Januari	7175,20	43,80
⋮	⋮	⋮	⋮
352	18 Desember	4375,95	-240,95
353	19 Desember	1447,55	129,45
354	20 Desember	4369,98	251,02
355	21 Desember	4499,23	298,77
356	22 Desember	4608,30	-297,30
357	23 Desember	4370,78	-126,78
358	24 Desember	4327,86	-141,86
359	25 Desember	4286,87	62,13
360	26 Desember	4361,91	-85,91
361	27 Desember	4321,38	314,62
362	28 Desember	4508,27	-260,27
363	29 Desember	4316,24	60,76
364	30 Desember	4377,01	-19,01
365	31 Desember	4366,86	98,14

Lampiran 11 *Output* ARIMA Jumlah Produksi Minyak Bumi

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	0.19187	0.05204	3.69	0.0003	1	z	0
MA1_2	0.53695	0.05199	11.48	<.0001	2	z	0
NUM1	-1486.6	63.92931	-22.47	<.0001	0	A047	0
NUM2	-1189.3	76.60933	-15.51	<.0001	0	A042	0
NUM3	-1223.5	54.21361	-22.57	<.0001	0	A039	0
NUM4	-991.30519	54.29444	-18.26	<.0001	0	A0242	0
NUM5	-923.19529	54.66383	-16.89	<.0001	0	A0157	0
NUM6	793.88657	71.88304	11.04	<.0001	0	LS52	0
NUM7	-731.00219	66.67418	-10.96	<.0001	0	LS332	0
NUM8	1563.1	98.01575	15.95	<.0001	0	A0284	0
NUM9	1249.8	82.14476	15.11	<.0001	0	A0283	0
NUM10	804.107453	63.49898	12.66	<.0001	0	LS293	0
NUM11	-617.30874	62.87990	-9.82	<.0001	0	A0281	0
NUM12	-559.34657	61.94369	-9.03	<.0001	0	A0327	0
NUM13	1370.1	105.81220	12.95	<.0001	0	LS318	0
NUM14	-516.52443	61.19460	-8.44	<.0001	0	LS280	0
NUM15	568.77268	62.13740	9.15	<.0001	0	LS307	0
NUM16	425.97861	62.16963	6.85	<.0001	0	A062	0
NUM17	297.95531	55.45704	5.37	<.0001	0	A0300	0
NUM18	-377.74379	84.48745	-4.47	<.0001	0	LS329	0
NUM19	-433.57419	82.96152	-5.23	<.0001	0	LS316	0
NUM20	-340.62876	65.35916	-5.21	<.0001	0	LS106	0
NUM21	764.69798	83.21458	9.19	<.0001	0	LS53	0
NUM22	-675.79607	77.65321	-8.70	<.0001	0	A0285	0
NUM23	409.36267	76.33894	5.36	<.0001	0	A043	0
NUM24	301.44830	57.92831	5.20	<.0001	0	A0304	0
NUM25	-363.73408	64.70996	-5.62	<.0001	0	LS88	0
NUM26	346.56078	57.52434	6.02	<.0001	0	LS122	0
NUM27	-235.10473	59.95529	-4.92	<.0001	0	A0324	0
NUM28	289.58033	58.73041	4.93	<.0001	0	A066	0
NUM29	-268.21318	55.25188	-4.85	<.0001	0	A070	0
NUM30	-248.56176	54.66334	-4.55	<.0001	0	A0131	0
NUM31	-327.01794	64.15882	-5.10	<.0001	0	LS292	0
NUM32	261.41705	54.34216	4.81	<.0001	0	A0236	0
NUM33	208.06741	54.19479	3.84	0.0002	0	A0223	0
NUM34	-671.05442	104.50353	-6.42	<.0001	0	A0318	0
NUM35	-284.54800	80.58449	-3.53	0.0005	0	LS317	0
NUM36	-344.72081	80.29671	-4.30	<.0001	0	LS331	0
NUM37	-252.98991	56.24867	-4.50	<.0001	0	A0177	0
NUM38	222.18256	61.51853	3.61	0.0004	0	A0109	0
NUM39	-179.15227	56.59015	-3.17	0.0017	0	A058	0
NUM40	-260.27362	63.38649	-4.11	<.0001	0	LS103	0
NUM41	-294.63600	67.41671	-4.37	<.0001	0	LS312	0
NUM42	-373.02311	66.19903	-5.63	<.0001	0	LS180	0
NUM43	208.84239	70.10970	2.98	0.0031	0	LS326	0
NUM44	180.76661	60.53726	2.99	0.0031	0	LS114	0
NUM45	-188.61107	61.51679	-3.07	0.0024	0	LS164	0
NUM46	-242.25789	66.02911	-3.67	0.0003	0	LS95	0
NUM47	-153.67601	54.81800	-2.80	0.0054	0	A075	0
NUM48	458.18508	55.55458	8.25	<.0001	0	A0274	0
NUM49	-466.98178	79.38755	-5.88	<.0001	0	LS51	0
NUM50	368.55431	60.30495	6.11	<.0001	0	LS273	0
NUM51	-320.69649	64.06426	-5.01	<.0001	0	LS184	0
NUM52	247.88846	87.15249	2.84	0.0044	0	A054	0
NUM53	-199.02592	56.59549	-3.52	0.0005	0	LS141	0
NUM54	-294.55253	81.02016	-3.64	0.0003	0	A0319	0
NUM55	-694.89390	69.96182	-9.93	<.0001	0	A064	0
NUM56	327.25633	66.47936	4.92	<.0001	0	LS64	0
NUM57	-131.28582	61.35718	-2.14	0.0332	0	LS161	0

Lampiran 11 (Lanjutan)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.51	4	0.6432	-0.020	-0.031	0.013	-0.028	-0.062	0.030
12	5.88	10	0.9255	0.021	-0.004	0.001	0.070	0.061	0.015
18	9.07	16	0.9104	0.067	-0.024	0.022	0.008	0.039	0.039
24	14.01	22	0.9012	-0.006	0.004	0.068	0.038	-0.047	-0.042
30	17.71	28	0.9332	0.063	-0.017	0.009	-0.020	0.049	-0.051
36	23.86	34	0.9025	0.021	0.003	-0.045	-0.047	0.088	-0.058

Tests for Normality

Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W	0.993036	Pr < W 0.1044
Kolmogorov-Smirnov	D	0.043587	Pr > D 0.1023
Cramer-von Mises	W-Sq	0.151001	Pr > W-Sq 0.0234
Anderson-Darling	A-Sq	0.849175	Pr > A-Sq 0.0295

Lampiran 12 *Output* ARIMA Jumlah Produksi Gas Bumi

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	0.88073	0.04201	20.96	<.0001	1	Z	0
AR1_1	0.41492	0.08161	5.08	<.0001	1	Z	0
NUM1	-2992.3	163.92427	-18.25	<.0001	0	A0107	0
NUM2	-3105.3	160.54225	-19.34	<.0001	0	A042	0
NUM3	-2804.6	160.82554	-17.44	<.0001	0	A0339	0
NUM4	-1877.4	175.05955	-10.72	<.0001	0	A0281	0
NUM5	-1627.3	175.18338	-9.29	<.0001	0	A0280	0
NUM6	-1526.5	160.12840	-9.53	<.0001	0	A0242	0
NUM7	-928.84616	160.92101	-5.77	<.0001	0	A0117	0
NUM8	-929.10022	163.05979	-5.70	<.0001	0	A0312	0
NUM9	-742.05313	160.86361	-4.61	<.0001	0	A0141	0
NUM10	-689.68382	213.27800	-3.23	0.0014	0	A0315	0
NUM11	-470.30280	161.54039	-2.91	0.0039	0	A0182	0
NUM12	1346.5	135.74437	9.92	<.0001	0	LS274	0
NUM13	1538.2	155.38163	10.29	<.0001	0	LS52	0
NUM14	-1559.1	164.43219	-9.48	<.0001	0	LS55	0
NUM15	1109.3	145.05999	7.65	<.0001	0	LS114	0
NUM16	-1321.5	147.08725	-8.98	<.0001	0	LS32	0
NUM17	-1541.2	189.67622	-8.13	<.0001	0	LS316	0
NUM18	1051.2	158.28016	6.64	<.0001	0	LS109	0
NUM19	-978.68404	139.81082	-7.00	<.0001	0	LS196	0
NUM20	688.35664	161.58609	4.26	<.0001	0	LS320	0
NUM21	-887.29043	138.92230	-6.39	<.0001	0	LS285	0
NUM22	-959.88743	168.17911	-5.71	<.0001	0	LS331	0
NUM23	597.13840	139.69624	4.27	<.0001	0	LS294	0
NUM24	741.93394	152.54079	4.86	<.0001	0	LS325	0
NUM25	1041.2	155.11865	6.71	<.0001	0	LS307	0
NUM26	-671.21534	168.04673	-3.99	<.0001	0	LS190	0
NUM27	-529.41893	148.67168	-3.56	0.0004	0	LS105	0
NUM28	456.99466	141.28260	3.23	0.0014	0	LS65	0
NUM29	-505.26302	148.96544	-3.39	0.0008	0	LS155	0
NUM30	-481.99191	139.76324	-3.59	0.0003	0	LS222	0
NUM31	398.02490	131.14112	3.04	0.0025	0	LS10	0
NUM32	-605.91062	160.40597	-3.78	0.0002	0	A0210	0
NUM33	717.90996	173.39318	4.14	<.0001	0	A0261	0
NUM34	426.91626	177.23906	2.41	0.0166	0	A032	0
NUM35	630.88770	173.31459	3.64	0.0003	0	A0262	0
NUM36	-415.67337	188.91846	-2.20	0.0286	0	A0314	0
NUM37	773.90025	160.93484	4.81	<.0001	0	A049	0
NUM38	-4653.0	162.83800	-28.61	<.0001	0	A0157	0
NUM39	-615.68137	160.79983	-3.83	0.0002	0	A0166	0
NUM40	799.54482	174.69258	4.58	<.0001	0	A0300	0
NUM41	646.13123	161.04031	4.01	<.0001	0	A0304	0
NUM42	433.30801	160.94757	2.69	0.0075	0	A0115	0
NUM43	471.12081	174.50494	2.70	0.0073	0	A0301	0
NUM44	-747.29781	150.44408	-4.97	<.0001	0	LS159	0
NUM45	514.96623	155.75083	3.31	0.0011	0	LS185	0
NUM46	391.94943	163.42634	2.40	0.0171	0	LS333	0
NUM47	-400.16685	174.78287	-2.29	0.0228	0	LS188	0
NUM48	-629.59527	162.42769	-3.87	0.0001	0	A061	0
NUM49	454.22270	154.74388	2.94	0.0036	0	LS59	0
NUM50	-464.50306	166.20615	-2.79	0.0055	0	LS310	0
NUM51	-353.86559	134.02302	-2.64	0.0087	0	LS171	0
NUM52	382.19978	161.30725	2.37	0.0185	0	A0275	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.16	4	0.3842	-0.011	-0.010	0.098	-0.038	0.019	-0.002
12	13.18	10	0.2139	0.051	-0.037	-0.098	-0.049	-0.080	0.050
18	19.41	16	0.2481	0.025	-0.006	0.005	0.033	-0.120	0.026
24	23.81	22	0.3573	-0.009	-0.066	0.059	0.042	-0.005	0.045
30	35.08	28	0.1674	0.076	0.093	0.034	0.094	-0.011	-0.070
36	38.75	34	0.2640	0.013	-0.001	-0.056	0.013	-0.051	0.057
42	44.51	40	0.2876	-0.009	-0.013	0.016	0.111	0.041	-0.011
48	56.30	46	0.1421	0.108	0.016	0.002	0.126	0.032	0.020

Lampiran 12 (Lanjutan)

Tests for Normality			
Test	--Statistic--	----p Value-----	
Shapiro-Wilk	W 0.992155	Pr < W	0.0619
Kolmogorov-Smirnov	D 0.044101	Pr > D	0.0940
Cramer-von Mises	W-Sq 0.156229	Pr > W-Sq	0.0208
Anderson-Darling	A-Sq 0.927369	Pr > A-Sq	0.0198

Lampiran 13 *Output Neural Network* Jumlah Produksi Minyak Bumi

Case Processing Summary

	N	Percent
Sample Training	347	100,0%
Valid	347	100,0%
Excluded	18	
Total	365	

Network Information

Input Layer	Covariates	1	Yt_1_oil	
		2	Yt_2_oil	
		3	Yt_3_oil	
		4	Yt_4_oil	
	Number of Units ^a			4
	Rescaling Method for Covariates		Standardized	
Hidden Layer(s)	Number of Hidden Layers			1
	Number of Units in Hidden Layer 1 ^a			5
	Activation Function		Sigmoid	
Output Layer	Dependent Variables	1	Oil	
	Number of Units			1
	Rescaling Method for Scale Dependents		Standardized	
	Activation Function		Identity	
	Error Function		Sum of Squares	

a. Excluding the bias unit

Model Summary

Training	Sum of Squares Error	30,063
	Relative Error	,174
	Stopping Rule Used	Relative change in training error criterion (.0001) achieved
	Training Time	0:00:00,06

Dependent Variable: Oil

Lampiran 13 (Lanjutan)

Parameter Estimates

Predictor		Predicted					Oil
		Hidden Layer 1					
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	
Input Layer	(Bias)	,802	-,096	,101	,017	-,090	
	Yt_1_oil	-1,933	-,353	-,179	,225	-,137	
	Yt_2_oil	,449	-,483	-,311	,222	-,047	
	Yt_3_oil	,116	,370	-,226	-,296	,646	
	Yt_4_oil	,237	-,378	-,443	,359	,190	
Hidden Layer 1	(Bias)						,995
	H(1:1)						-2,266
	H(1:2)						-,544
	H(1:3)						-,289
	H(1:4)						,481
	H(1:5)						1,356

Lampiran 14 *Output Neural Network* Jumlah Produksi Gas Bumi**Case Processing Summary**

		N	Percent
Sample	Training	349	100,0%
	Valid	349	100,0%
	Excluded	4	
	Total	353	

Network Information

Input Layer	Covariates	1	Yt_1_gas
		2	Yt_2_gas
	Number of Units ^a		2
	Rescaling Method for Covariates		Standardized
Hidden Layer(s)	Number of Hidden Layers		1
	Number of Units in Hidden Layer 1 ^a		2
	Activation Function		Sigmoid
Output Layer	Dependent Variables	1	gas
	Number of Units		1
	Rescaling Method for Scale Dependents		Standardized
	Activation Function		Identity
	Error Function		Sum of Squares

a. Excluding the bias unit

Model Summary

Training	Sum of Squares Error	26,873
	Relative Error	,154
	Stopping Rule Used	Relative change in training error criterion (.0001) achieved
	Training Time	0:00:00,03

Dependent Variable: gas

Parameter Estimates

		Predicted		
		Hidden Layer 1		Output Layer
Predictor		H(1:1)	H(1:2)	gas
Input Layer	(Bias)	-,408	,462	
	Yt_1_gas	1,137	-1,083	
	Yt_2_gas	,104	-,254	
Hidden Layer 1	(Bias)			,344
	H(1:1)			1,743
	H(1:2)			-1,860

Lampiran 15 *Output* Hibrida ARIMA-*Neural Network* Jumlah Produksi Minyak Bumi

Case Processing Summary

		N	Percent
Sample	Training	346	100,0%
	Valid	346	100,0%
	Excluded	9	
	Total	355	

Network Information

Input Layer	Covariates	1	Nt_1	
		2	Nt_2	
		3	Nt_3	
		4	Nt_4	
	Number of Units ^a			4
	Rescaling Method for Covariates		Standardized	
Hidden Layer(s)	Number of Hidden Layers			1
		Number of Units in Hidden Layer 1 ^a		10
	Activation Function		Sigmoid	
Output Layer	Dependent Variables	1	Nt	
		Number of Units		1
		Rescaling Method for Scale Dependents		Standardized
		Activation Function		Identity
	Error Function		Sum of Squares	

a. Excluding the bias unit

Model Summary

Training	Sum of Squares Error	149,573
	Relative Error	,867
	Stopping Rule Used	Maximum number of epochs (100) exceeded
	Training Time	0:00:00,09

Dependent Variable: Nt

Lampiran 16 *Output* Hibrida ARIMA-NN Jumlah Produksi Gas Bumi

Case Processing Summary

		N	Percent
Sample Training		348	100,0%
Valid		348	100,0%
Excluded		5	
Total		353	

Network Information

Input Layer	Covariates	1	NT_1
		2	NT_2
	Number of Units ^a		2
	Rescaling Method for Covariates		Standardized
Hidden Layer(s)	Number of Hidden Layers		1
	Number of Units in Hidden Layer 1 ^a		1
	Activation Function		Sigmoid
Output Layer	Dependent Variables	1	Nt
	Number of Units		1
	Rescaling Method for Scale Dependents		Standardized
	Activation Function		Identity
	Error Function		Sum of Squares

a. Excluding the bias unit

Model Summary

Training	Sum of Squares Error	173,732
	Relative Error	1,001
	Stopping Rule Used	Relative change in training error criterion (.0001) achieved
	Training Time	0:00:00,02

Dependent Variable: NT

Lampiran 16 (Lanjutan)

Parameter Estimates

Predictor		Predicted	
		Hidden Layer 1	Output Layer
		H(1:1)	Nt
Input Layer	(Bias)	,315	
	Nt_1	-,318	
	Nt_2	,085	
Hidden Layer 1	(Bias)		,197
	H(1:1)		-,335

SURAT KETERANGAN

Saya yang bertanda tangan di bawah ini menerangkan bahwa :

1. Mahasiswa Statistika FMIPA-ITS dengan identitas sebagai berikut :

Nama : Windra Cinde Prameswari
NRP : 1314105010

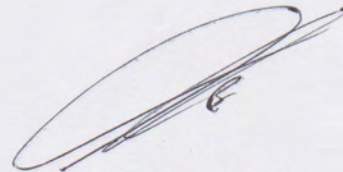
Telah mengambil data di instansi/perusahaan kami :

Nama Instansi : PT X
Divisi/Bagian : Operasi dan Produksi

Sejak tanggal 16 Februari 2016 sampai dengan 18 Februari 2016 untuk keperluan Tugas Akhir / ~~Thesis~~ Semester ~~Gasal~~/Genap* 2015/2016.

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

Surabaya, 18 Februari 2016
Pimpinan Perusahaan
Divisi Operasi dan Produksi



Maryono, S.T.

NIP. 102933

*(Coret yang tidak perlu)

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan yang dilakukan maka kesimpulan dari penelitian ini antara lain.

1. Berdasarkan analisis deskriptif pada data jumlah produksi minyak dan gas bumi selama tahun 2015 diketahui bahwa, rata-rata jumlah produksi minyak bumi setiap hari cenderung konstan selama tahun 2015, yaitu sekitar 2500 barel setiap hari. Jumlah produksi terendah sebesar 649,5 barel terjadi pada hari Sabtu, dengan median sebesar 2593,5 barel, kuartil atas sebesar 3041,3 dan kuartil bawah sebesar 2018,13 barel. Untuk gas bumi memiliki rata-rata jumlah produksi setiap hari juga cenderung konstan yaitu sebesar 5500 mScf. Pada hari Sabtu selama tahun 2015 terdapat jumlah produksi yang sangat tinggi dan sangat rendah. Jumlah produksi paling rendah sebesar 1577 mScf dengan median sebesar 6008,5, kuartil atas sebesar 6858,5 mScf, dan kuartil bawah sebesar 4398,5 mScf.
2. Pemodelan pada data jumlah produksi minyak bumi diperoleh hasil bahwa model terbaik adalah model hibrida *ARIMA-neural network*. Hasil ramalan yang diperoleh untuk 14 hari ke depan jumlah produksi minyak bumi cenderung konstan.
3. Berdasarkan hasil dari pemodelan pada data jumlah produksi gas bumi tahun 2015, diperoleh hasil bahwa model terbaik dalam memodelkan data tersebut adalah model *neural network*. Hasil ramalan untuk 14 hari ke depan mengalami peningkatan jumlah produksi, namun tidak signifikan.

5.2 Saran

Saran dari hasil analisis dan pembahasan yang dilakukan pada penelitian ini yaitu untuk produksi minyak bumi mulai tanggal 1 Januari 2016 hingga 14 Januari 2016 menghasilkan jumlah yang konstan, sehingga tidak perlu dilakukan *treatment* pada sumur-

sumur yang ada di *platform* “MK”. Begitu juga dengan produksi gas bumi pada tanggal 1-14 Januari 2016 menghasilkan jumlah gas bumi yang cenderung naik, sehingga pada selang waktu 2 minggu pertama tahun 2016 perusahaan tidak perlu melakukan *treatment* pada sumur-sumur yang berada di *platform* “MK”.

DAFTAR PUSTAKA

- Adnyana, B. O. S. (2013). *Penerapan Bootstrap Pada Neural Network Untuk Peramalan Produksi Minyak Mentah di Indonesia*. Tugas Akhir, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.
- Ansyari, I. (2015). *Beberapa Fakta Menarik Tentang Minyak Bumi*. <http://learnmine.blogspot.co.id/2015/04/fakta-menarik-tentang-minyak-bumi.html>. Diakses pada tanggal 10 Februari 2016.
- Ardiansyah, I. R. (2014). *Proses Pengolahan Minyak Bumi (Minyak Mentah dan Komposisinya)*. <http://ichsanrizqia17994.weebly.com/blog/proses-pengolahan-minyak-bumi-minyak-mentah-dan-komposisinya>. Diakses pada 11 Februari 2016.
- Bowerman, B. L., & O'Connell, R. T. (1993). *Forecasting and Time Series : an Applied Approach, 2nd Edition*. California: Duxbury Press.
- Box, G., Jenkins, G., dan Reinsel, G. (2008). *Time Series Analysis Forecasting and Control, 4th edition*. Canada: Wiley & Sons, Inc.
- Crone, S. F. Dan Kourentzes, N. (2009). *Input-variable Spesification for Neural Network – an Analysis of Forecasting low and high Time Series Frequency*. Proceedings of International Joint Conference on Neural Network. 619-626.
- Cryer, J. D., & Chan, K. –S. (2008). *Time Series Analysis with Applications in R, 2nd edition*. USA: Springer Texts Statistics.
- Daniel, W. W. (1989). *Statistika Non Parametrik Terapan*. Jakarta : Gramedia.

- Faruk, D. O. (2010). *A Hybrid Neural Network and ARIMA Model for Water Quality Time Series Prediction*. Artificial Intelligence, 586-594.
- Fausett, L. (1994). *Fundamental of Neural Network: Architectures, algorithm and applications*. Prantice Halt.
- Jan, S., & Katarina, H. (2010). *The Implementation of Hybrid ARIMA-Neural Network Prediction Model*. Journal of Applied Mathematics, volume 3, 124-130.
- Khashei, M., & Bijari, M. (2011). *A Novel Hybridization of Artificial Neural Network and ARIMA Model for Time Series Forecasting*. Applied Soft Computing, 2664 – 2675.
- Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan (Menggunakan MATLAB & Excel Link)*. Yogyakarta: Graha ilmu.
- Kusumaningrum, O. (2012). *Peramalan Kebutuhan Bahan Bakar Premium di Depot Ampenan Dengan Metode Hibrida ARIMA – NN Untuk Optimasi Persediaan*. Tugas Akhir, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.
- Makridarkis, S., Wheelwright, S.C., dan McGee, V.E. (1999). Jilid 1 Edisi Kedua, Terjemahan Ir. Hari Suminto. *Metode dan Aplikasi Peramalan*. Jakarta : Bina Rupa Aksara.
- Samperuru, D. (2007). *Dari Mana Datangnya Minyak Bumi*. Buku Pintar Migas Indonesia, 1-17.
- Suhartono. (2007). *FeedForward Neural Network untuk Pemodelan Runtun Waktu*. Disertasi, Jurusan Matematika, Universitas Gadjah Mada.
- Utami, M. B. (2013). *Sumber Daya Alam yang Tidak Dapat Diperbaharui*. http://meibxdfst12.web.unair.ac.id/artikel_detail-73566-Catatan%20kuliahSUMBER%20DAYA%20ALAM%20YANG%20TIDAK%20DAPAT%20DIPERBAHARUI.html. Diakses pada 12 April 2016

- Walpole, R. E. (1995). *Pengantar Metode Statistik*. Edisi ke 3. Diterjemahkan oleh: Ir. Bambang Sumantri. Jakarta: PT Gramedia Pustaka Utama.
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate Methods*, 2nd Edition. New York: Pearson.
- Zhang, G. P. (2003). *Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model*. Elsevier, 159 – 175.
- Zheng, F., & Zhong, S. (2011). *Time Series Forecasting Using a Hybrid RBF Neural Network and AR Model Based on Binomial Smoothing*. World Academy of Science and Technology, volume 5, 419-423.

“Halaman ini sengaja dikosongkan”

BIODATA PENULIS



Windia Cinde Prameswari atau yang akrab disapa dengan Memes merupakan anak bungsu dari 3 bersaudara yang lahir pada 30 September 1993 di Surabaya. Penulis tinggal di Jl. Kendangsari III/52 YKP, Surabaya, Jawa Timur. Penulis telah menyelesaikan pendidikan formal di SDN Kendangsari I Surabaya, SMPN 6 Surabaya, SMA Trimurti Surabaya, D3 Statistika ITS, dan melanjutkan kuliah S1 di Statistika ITS tahun 2014. Selama masa perkuliahan penulis aktif dalam bidang non akademik atau organisasi

yaitu HIMASTA-ITS sebagai staf Hubungan Luar periode 2012/2013, anggota pers HIMASTA-ITS periode 2012/2013, sekretaris departemen Hubungan Luar HIMASTA-ITS periode 2013/2014, dan bendahara pers HIMASTA-ITS periode 2013/2014. Penulis juga pernah mengikuti beberapa karya ilmiah dan PKM yang di danai, yaitu PKM-GT dan PKMP. Segala saran dan kritik yang membangun serta bagi yang ingin berdiskusi lebih lanjut dengan penulis terkait dengan Tugas Akhir ini dapat mengirimkan email ke windiaprames@gmail.com atau menghubungi ke nomor 085730250390.